

الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة غرداية

Université de Ghardaïa

N° d'enregistrement

/ / / / /



كلية العلوم والتكنولوجيا

Faculté des Sciences et de la Technologie

قسم الآلية والكهروميكانيك

Département d'Automatique et Électromécanique

Mémoire de fin d'études, en vue de l'obtention du diplôme

Master

Domaine : Sciences et Technologie

Filière : Génie mécanique

Spécialité : Énergies Renouvelables en mécanique

Préparé par : GOSSA EL HADJ AISSA

Thème

***Prédiction de la vitesse du vent à l'aide d'un
Modèle hybride CEEMDAN-GRU***

Soutenu publiquement en juin 2026

Devant le jury composé de :

BAKKAR Belkacem	Maître de Conférences A	Université de Ghardaïa	Présidente
FERKOUS Khaled	Maître de Conférences A	Université de Ghardaïa	Encadrant
MEDOUKALI Hemza	Maître de Conférences A	Université de Ghardaïa	Examineur
BOUCHELGA Fatma	Maître de Conférences A	Université de Ghardaïa	Examineur
OULAD Aide fatima zohra	Doctorante	Université de Ghardaïa	Co-encadreur

Année universitaire 2025 / 2026

Dédicaces

Dédicaces

Je dédie mon travail :

- À mes très chers parents, pour leur amour inconditionnel, leurs sacrifices infinis et leurs prières qui m'ont éclairé le chemin tout au long de ma vie. Aucune dédicace ne saurait exprimer mon immense gratitude et mon profond respect.
- À ma femme et mes enfants, mes frères et sœurs, pour leur soutien moral, leurs encouragements constants et leur présence à mes côtés dans les moments de doute.
- À toute ma famille, proches et lointains, pour leur affection et leur bienveillance.

Remerciements

Remerciements

Je tiens tout d'abord à exprimer ma profonde gratitude à mon encadrant de mémoire, **Dr FERKOUS KHALED**, Maître de conférences à l'Université de Ghardaïa, pour sa disponibilité, ses précieux conseils, sa rigueur scientifique ainsi que pour le soutien constant qu'il m'a apporté tout au long de la réalisation de ce travail.

Mes sincères remerciements s'adressent également aux membres du jury, qui ont bien voulu consacrer leur temps à l'évaluation de ce mémoire et me faire l'honneur de participer à ma soutenance.

Je tiens enfin à remercier toutes les personnes qui, de près ou de loin, ont contribué à l'aboutissement de ce travail.

ملخص

يركز هذا البحث على تطوير والتحقق من صحة منهجية نمذجة هجينة عالية الأداء للتنبؤ بالسلاسل الزمنية غير المستقرة والمتقطعة، مع تطبيق محدد على سرعة الرياح. يجمع التصميم المقترح، المسمى CEEMDAN-GRU، بين طريقة التحلل التجريبي التكميلي (CEEMDAN) وكفاءة الشبكات العصبية ذات الوحدات المتكررة البوابية (GRU) تتيح تقنية CEEMDAN تقسيم الإشارة الأصلية إلى مكونات جوهرية (IMFs)، مما يعزل الضوضاء عالية التردد بفعالية لتحسين تعلم خلايا GRU على الديناميكيات الزمنية قصيرة وطويلة الأجل. بفضل استجابته للتغيرات المفاجئة وانعدام التأخير الزمني، يوفر هذا التصميم حلاً فعالاً لإدارة طاقة الرياح. تشمل التوجهات المستقبلية لهذه الدراسة دمج خوارزميات التحسين الميتاهوريستية لضبط المعلمات الفائقة تلقائياً، بالإضافة إلى تطبيق هذا النموذج للتنبؤ بمصادر الطاقة المتجددة المتقطعة الأخرى، ولا سيما الطاقة الشمسية الكهروضوئية.

الكلمات المفتاحية:

التنبؤ بسرعة الرياح، السلاسل الزمنية، النموذج الهجين، CEEMDAN، GRU، الطاقة المتجددة

Résumé

Ce travail de recherche est dédié au développement et à la validation d'une approche de modélisation hybride performante pour la prévision de séries temporelles non stationnaires et intermittentes, avec une application ciblée sur la vitesse du vent. L'architecture proposée, baptisée CEEMDAN-GRU, associe la méthode de décomposition empirique adaptative Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) à l'efficacité séquentielle des réseaux de neurones récurrents Gated Recurrent Unit (GRU). Le déploiement de la technique CEEMDAN permet de segmenter le signal d'origine en composantes intrinsèques (IMFs), isolant efficacement le bruit à haute fréquence afin d'optimiser l'apprentissage des cellules GRU sur les dynamiques temporelles à court et à long terme. Grâce à sa réactivité face aux variations brusques et à l'absence de déphasage temporel (time-lag), cette architecture offre une solution robuste pour la gestion de l'énergie éolienne. Les perspectives de cette étude visent l'incorporation d'algorithmes d'optimisation méta-heuristiques pour le réglage automatique des hyperparamètres, ainsi que la transposition de ce modèle à la prédiction d'autres sources renouvelables intermittentes, notamment l'énergie solaire photovoltaïque.

Mots-clés : *Prédiction de la vitesse du vent, Séries temporelles, Modèle hybride, CEEMDAN, GRU, Énergie renouvelable.*

Abstract

With a particular focus on wind speed, this study develops and validates a high-performance hybrid modeling strategy for predicting non-stationary and intermittent time series. The suggested design, called CEEMDAN–GRU, combines the sequential efficiency of Gated Recurrent Unit (GRU) neural networks with the adaptive empirical decomposition technique Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN). In order to maximize GRU cell learning on both short- and long-term temporal dynamics, the CEEMDAN approach effectively isolates high-frequency noise by segmenting the original signal into intrinsic components (IMFs). Thanks to its responsiveness to abrupt changes and the absence of time lag, this architecture offers a robust solution for wind energy management. The future directions of this study include incorporating metaheuristic optimization algorithms for the automatic tuning of hyperparameters, as well as applying this model to the prediction of other intermittent renewable energy sources, particularly solar photovoltaic energy.

Keywords : *Wind speed prediction, Time series, Hybrid model, CEEMDAN, GRU, Renewable energy*

Table des matières

Table des matières

Dédicaces.....	I
Remerciements	II
ملخص.....	III
Résumé	IV
Abstract	III
Liste des Figures.....	I
Listes des abréviations.....	1
Introduction générale.....	1
Chapitre 1 : Généralité sur l'énergie éolienne et la prévision du vent.....	
1.1. Introduction	3
1.2. Electricité éolienne	4
1.3. État de l'art sur les approches hybrides de prévision de la vitesse du vent	6
1.4. Principe de conversion de l'énergie cinétique du vent	8
1.5. Types d'éoliennes.....	8
1.5.1. L'éolienne à axe vertical.....	8
1.5.2. L'éolienne à axe horizontal	9
1.5.3. Les composants principaux d'une éolienne.....	10
1.6. Influence de la vitesse du vent sur la production électrique	11
1.7. Caractéristique de la vitesse du vent.....	12
1.7.1. Nature aléatoire et non stationnaire du vent :	12
1.7.2. Variabilité temporelle (horaire, journalière et saisonnières)	12
1.7.3. Facteurs influençant la vitesse du vent	13
1.8. Prévision de la vitesse du vent.....	13
1.8.1. Types de prévision.....	13
1.8.2. Méthodes de Prévision.....	14
1.8.2.1. Méthodes Classiques	14
1.8.2.2. Méthodes statistiques.....	14
a) Modèle Autorégressif (AR).....	14
b) Modèle Autorégressif (ARMA).....	15
c) Modèle Autorégressif (ARIMA) :	15
d) Modèle Autorégressif (SARIMA).....	15
1.8.2.3. Méthodes basées sur l'intelligence artificielle.....	17
1.9. Données de vent et sources ouvertes	18

Table des matières

1.10.	Conclusion.....	18
Chapitre 2: Modélisation et méthodologie		
2.1.	Introduction	19
2.2.	Prétraitement des données	20
2.2.1.	Sélection de la station météorologique	20
2.2.2.	Nettoyage des données	20
2.2.3.	Normalisation / standardisation	21
2.2.4.	Découpage des données (train / validation / test) :	21
2.3.	Décomposition CEEMDAN	22
2.3.1.	Principe de CEEMDAN	22
2.3.2.	Application de CEEMDAN aux séries de vent	23
2.3.3.	Rôle de la décomposition dans la réduction du bruit.....	24
2.4.	Réseau de neurones GRU	25
2.4.1.	Structure interne	25
2.4.2.	A.. Avantages du GRU par rapport à LSTM B.. Inconvénients du modèle CEEMDAN-GRU.	26
2.4.3.	Équations principales.....	27
2.5.	Modèle hybride CEEMDAN–GRU proposé.....	27
2.5.1.	Architecture globale du modèle.....	27
2.6.	Métriques d'évaluation	29
2.6.1.	Erreur quadratique moyenne (RMSE).....	29
2.6.2.	Erreur quadratique moyenne normalisée (NRMSE).....	29
2.6.3.	Coefficient de détermination R^2	29
2.7.	Conclusion.....	30
Chapitre 3 : Résultats et Discussion		
3.1.	Introduction	31
3.2.	Analyse statistique et fréquentielle des données de vitesse du vent	31
3.3.	Les Données Originales des simulations	33
3.4.	Choix du meilleur décalage temporel.....	34
3.5.	Comparaison des modèles hybrides CEEMDAN-GRU et WD-GRU	39
3.6.	Évaluation des performances de modèle proposé selon différents horizons de prévision.....	43
3.7.	Conclusion.....	48
Conclusion Générale		49
Références		51

Liste des Figures

Liste des Figures

Figure 1 : Éolienne à axe vertical	04
Figure 2 : Éolienne à axe horizontale	05
Figure 3 : Les différents composants d'une éolienne	09
Figure 4 : Architecture détaillée du découpage des données	10
Figure 5 : Schéma de décomposition	10
Figure 6 : Structure architecturale GRU	22
Figure 7 : Organigramme détaillé de l'hybridation CEEMDAN-GRU	24
Figure 8 : Schéma explicatif du modèle CEEMDAN-GRU	25
Figure 9 : Spectres du signal original et du résidu selon la fréquence normalisée	28
Figure 10 : Signal de la vitesse du vent avant normalisation	32
Figure 11 : Signal de la vitesse du vent après normalisation	33
Figure 12 : Comparaison de performance entre les trois Lags	34
Figure 13 : Comparaison du coefficient de détermination (R^2) entre les trois Lags	35
Figure 14 : Comparaison du RMSE entre les trois Lags	36
Figure 15 : Comparaison du NRMSE entre les trois Lags	37
Figure 16 : Résultats (réel vs prédiction) avec Lag 2	38
Figure 17 : Graphe des résultats avec Lag 2	39
Figure 18 : Décomposition adaptative du signal de vitesse du vent en IMF et résidu	41
Figure 19 : Comparaison de la distribution des erreurs entre WD-GRU et CEEMDAN-GRU	42
Figure 20 : Évolution du coefficient de détermination (R^2) selon l'horizon de prévision	43
Figure 21 : (a) RMSE, (b) NRMSE des modèles comparés	44
Figure 22 : Comparaison temporelle des valeurs réelles et prédites (CEEMDAN-GRU)	44
Figure 23 : Comportement dynamique local du modèle CEEMDAN-GRU	45
Figure 24 : Diagramme de dispersion et droite de régression	46
Figure 25 : Évolution temporelle des erreurs de prédiction	46

Liste des Figures

Figure 26 : Histogramme de distribution des erreurs de prédiction	47
Figure 27 : Synthèse des indicateurs de performance (R^2 , RMSE, NRMSE)	47

Listes des abréviations

Listes des abréviations

AESVD	Adaptive Ensembled Singular Value Decomposition
ANN	Artificial Neural Network (Réseau de neurones artificiels)
AR	Autoregressive (Autorégressif)
ARIMA	Autoregressive Integrated Moving Average (Modèle autorégressif intégré)
ARMA	Autoregressive Moving Average (Modèle autorégressif moyenne mobile)
AROME	Applications de la Recherche à l'Opérationnel à Mésos-Échelle
ARPEGE	Action de Recherche Petite Échelle Grande Échelle
ASSA	Adaptive Sparrow Search Algorithm
BB	Banc de batteries
BBC	Banc de batteries control
BBDC	Buck-Boost Bidirectional Converter
BPNN	Backpropagation Neural Network
CEEMD	Complementary Ensemble Empirical Mode Decomposition
CEEMDAN	Complete Ensemble Empirical Mode Decomposition with Adaptive Noise
CEWT	Complex Extended Wavelet Transform
CNN	Convolutional Neural Network
CGRU	Coupled/Convolutional Gated Recurrent Unit
DC	Direct Current
DCC	Deuxième chaîne de conversion
DG	Générateurs diesel
ECMWF	European Centre for Medium-Range Weather Forecasts
EEMD	Ensemble Empirical Mode Decomposition
ELM	Extreme Learning Machine
EMD	Empirical Mode Decomposition
ER	Énergie renouvelable
GAS	Générateurs asynchrones
GPV	Générateurs photovoltaïques

Listes des abréviations

GRU	Gated Recurrent Unit (Unité à portes)
GSAP	Générateur synchrone à aimant permanent
GWO	Grey Wolf Optimizer
HS-KELM	Hybrid Sine GWO – Kernel Extreme Learning Machine
IA / AI	Intelligence Artificielle / Artificial Intelligence
IGWO	Improved Grey Wolf Optimizer
IMF	Intrinsic Mode Function (Fonction de mode intrinsèque)
KELM	Kernel Extreme Learning Machine
LSTM	Long Short-Term Memory
MA	Moving Average (Moyenne mobile)
MAE	Mean Absolute Error (Erreur absolue moyenne)
MAPE	Mean Absolute Percentage Error (Erreur absolue en pourcentage)
MC	Markov Chain (Chaîne de Markov)
ML	Machine Learning (Apprentissage automatique)
MLI	Modulation à Largeur d'Impulsion
NOAA	National Oceanic and Atmospheric Administration
NREL	National Renewable Energy Laboratory
NIWE	National Institute of Wind Energy (Inde)
NWP	Numerical Weather Prediction (Prévision numérique du temps)
OLS	Ordinary Least Squares (Moindres carrés ordinaires)
PACF	Partial Autocorrelation Function
RNN	Recurrent Neural Network (Réseau de neurones récurrent)
SARIMA	Seasonal Autoregressive Integrated Moving Average
SE	Sample Entropy (Entropie d'échantillon)
VMD	Variational Mode Decomposition
WD	Wavelet Decomposition (Décomposition en ondelettes)
WWEA	World Wind Energy Association

Introduction générale

Introduction générale

La prévision de la vitesse du vent constitue aujourd'hui un enjeu majeur dans le domaine des énergies renouvelables, en particulier pour l'exploitation optimale de l'énergie éolienne. En effet, la nature fortement variable, non linéaire et non stationnaire des données de vent rend leur modélisation et leur prédiction particulièrement complexes. Cette difficulté a conduit les chercheurs à explorer de nouvelles approches basées sur l'intelligence artificielle afin d'améliorer la précision des modèles de prévision.

Parmi ces approches, les modèles hybrides combinant des techniques de décomposition des séries temporelles et des algorithmes d'apprentissage profond se sont révélés particulièrement efficaces. Dans ce contexte, les méthodes de décomposition telles que CEEMDAN permettent de transformer les signaux complexes en composantes plus simples et plus exploitables, facilitant ainsi le processus de prédiction. Associées à des réseaux de neurones récurrents tels que le GRU (Gated Recurrent Unit), ces techniques offrent une capacité accrue à capturer les dépendances temporelles et les dynamiques complexes des séries de vent. Dans cette optique, le présent mémoire. Il s'inscrit dans cette dynamique de recherche visant à améliorer la précision des prévisions de la vitesse du vent grâce à des modèles intelligents et robustes.

L'objectif principal de ce mémoire est de proposer et de développer un modèle hybride basé sur la méthode CEEMDAN combinée au réseau de neurones récurrents GRU, afin d'améliorer la précision de la prévision de la vitesse du vent. L'évaluation des performances du modèle est effectuée à l'aide de plusieurs métriques statistiques, notamment le coefficient de détermination (R^2), l'erreur quadratique moyenne (RMSE) ainsi que l'erreur quadratique moyenne normalisée (NRMSE), permettant ainsi de juger la fiabilité et la robustesse des résultats obtenus.

Le présent mémoire est structuré en trois chapitres complémentaires. Le premier chapitre est consacré à une étude bibliographique générale portant sur le potentiel éolien à l'échelle mondiale, ainsi qu'un état de l'art des principales approches basées sur l'intelligence artificielle utilisées pour la prévision de la vitesse du vent.

Le deuxième chapitre présente la méthodologie adoptée dans ce travail. Il décrit l'étude de cas retenue ainsi que les différentes architectures d'intelligence artificielle utilisées, à savoir CEEMDAN et GRU. Une attention particulière est accordée à leur principe de fonctionnement, ainsi qu'aux différentes stratégies d'hybridation mises en œuvre pour améliorer la performance du modèle de prédiction.

Enfin, le troisième chapitre est dédié à la présentation et à l'analyse des résultats expérimentaux. Il expose les différents graphes de simulation obtenus et propose une interprétation physique des comportements observés, afin de mieux comprendre les performances du modèle proposé.

Chapitre 1

Chapitre 01 : Généralité sur l'énergie éolienne et la prévision du vent

1.1.Introduction

La transition énergétique mondiale est une nécessité urgente face au réchauffement climatique, visant à décarboner l'économie d'ici 2050. Bien que les énergies fossiles représentent encore environ 80% de l'énergie primaire, une accélération massive vers les énergies renouvelables (solaire, éolien...etc) est en cours, soutenue par une électrification croissante, par la dominance fossile persistante (Pétrole, charbon et gaz naturel) dominant toujours le mix énergétique mondial, représentant près de 84 % de la consommation, et même Impératif climatique Pour respecter la trajectoire de 1,5°C, une réduction drastique des émissions est nécessaire, car les engagements actuels sont insuffisants. et la croissance des Énergies renouvelables (Le solaire et l'éolien connaissent une croissance exponentielle. La part des renouvelables dans l'électricité pourrait atteindre 82% d'ici 2050 selon les engagements.

Les énergies renouvelables (solaire, éolien, hydraulique, géothermie, biomasse) sont cruciales pour lutter contre le changement climatique en réduisant drastiquement les émissions de gaz à effet de serre. Elles garantissent une indépendance énergétique, favorisent la création d'emplois locaux et offrent une source d'énergie durable et inépuisable, indispensable à la transition écologique.

Selon les données recueillies par la Wind World Energy Association, 121'305 MW de puissance éolienne supplémentaire ont été raccordées dans le monde en 2024. La puissance éolienne installée dans le monde atteint ainsi un nouveau record avec 1'173'581 MW. Même si le taux de croissance a baissé, passant de 13 % en 2023 à 11,5 % en 2024, la part de l'éolien représente 10 % de la consommation d'électricité et dépasse désormais largement celle du nucléaire.




Fig.1 Puissance éolienne totale installée dans le monde.

1.2. Electricité éolienne

La part de l'électricité éolienne dans le monde couvre désormais bien plus de 10 % de la consommation mondiale d'électricité, soit bien plus que l'énergie nucléaire qui représentait 9 % en 2024. Dans plus de 30 pays, la part de l'énergie éolienne est supérieure à la moyenne mondiale de plus de 10 %. Onze pays produisent plus de 20 % de leur électricité à partir de l'énergie éolienne, et pour sept d'entre eux, la part d'électricité éolienne est même de 30 % ou plus : le Danemark, qui produit plus d'un kilowattheure d'électricité sur deux à partir de l'énergie éolienne, arrive en tête. Il est suivi de l'Allemagne, du Royaume-Uni, du Portugal, des Pays-Bas, de l'Irlande et de l'Uruguay. Tous ces pays montrent qu'il est possible d'atteindre une part mondiale de 40 à 50 % d'énergie éolienne dans la production d'électricité globale.




Fig. 2 la puissance éolienne totale installée dans le monde.

Dans de nombreux pays européens, le développement de l'éolien a été moins important qu'en 2023, notamment en Allemagne, en France, en Suède, aux Pays-Bas, en Pologne et au Portugal. En revanche, la taille du marché pour les nouvelles installations éoliennes a augmenté dans certains pays comme l'Espagne, l'Italie, la Finlande, le Danemark et la Lituanie.

L'Allemagne est à nouveau en tête des nouvelles installations avec 3,2 GW de puissance supplémentaire ; c'est toutefois un peu moins qu'en 2023, si bien que sa puissance totale s'élève désormais à 72,7 GW. Au total, cinq pays européens ont dépassé le seuil des 1 GW pour les nouvelles installations : l'Allemagne, le Royaume-Uni (2,2 GW de nouvelle puissance, 32,3 GW au total), la Finlande (1,4 GW de nouvelle puissance, 8,4 GW au total), l'Espagne (1,2 GW de nouvelle puissance, 32 GW au total) et la Suède (1 GW de nouvelle puissance, 17,3 GW au total).

Sur le continent africain, le développement éolien est encore une fois resté très faible. Le Maroc, numéro un du marché de l'énergie éolienne sur le continent, a raccordé 302 MW de nouvelles puissances, ce qui porte sa puissance totale à 2.4 GW. L'Égypte a construit légèrement plus avec 315 MW de puissances supplémentaires, ce qui porte sa puissance installée à 2.2 GW. Dans de nombreux pays africains, une part relativement importante de la population vit dans des zones isolées, sans raccordement au réseau. Ces pays se concentrent donc sur l'électrification rurale, pour laquelle de petites éoliennes peuvent très bien être utilisées en combinaison avec l'énergie solaire.

Pour notre cas la problématique de la variabilité et l'intermittence du vent constituent l'un des principaux défis techniques et économiques pour l'intégration massive de l'énergie éolienne dans

les réseaux électriques. Elles imposent des contraintes sur la stabilité du réseau, nécessitent des capacités de stockage et compliquent la gestion de l'équilibre entre l'offre et la demande, notre analyse de cette problématique, on peut dire qu'il y a une différence entre la variabilité et intermittence

Variabilité (court/moyen terme) : La vitesse du vent fluctue constamment (secondes, minutes, heures), entraînant une production électrique instable. L'énergie éolienne peut varier jusqu'à 90 % du temps.

Intermittence (long terme) : Le vent peut s'arrêter complètement pendant plusieurs jours, provoquant des périodes sans production.

1.3.État de l'art sur les approches hybrides de prévision de la vitesse du vent

La prévision de la vitesse du vent constitue un domaine de recherche particulièrement actif en raison de son importance dans la gestion et l'exploitation des systèmes éoliens. Au fil des années, plusieurs chercheurs ont proposé des modèles basés sur l'intelligence artificielle afin d'améliorer la précision des prévisions. Toutefois, les limites observées dans les modèles individuels ont conduit à l'émergence d'approches hybrides combinant différentes techniques de traitement des données et d'apprentissage automatique.

Dans cette optique, plusieurs travaux ont mis en évidence l'intérêt d'associer des méthodes de décomposition des séries temporelles à des réseaux de neurones profonds. Par exemple, l'étude réalisée par [1] a proposé un modèle hybride AESVD-CEWT-IGWO-GRU destiné à la prévision multivariée de la vitesse du vent. Les auteurs ont montré que la combinaison de plusieurs techniques permettait d'améliorer sensiblement les performances prédictives. Cette tendance a également été confirmée par [2], dont les résultats indiquent que les modèles hybrides surpassent généralement les modèles d'apprentissage automatique utilisés séparément.

D'autres chercheurs se sont intéressés à l'exploitation des méthodes de décomposition afin de mieux traiter le caractère non stationnaire des données éoliennes. Ainsi, [3] ont appliqué leur approche sur des données recueillies dans l'État du Gujarat en Inde et ont obtenu une précision supérieure à celle des méthodes conventionnelles. De même, [4] Dans le travail de Jiang et al. 2023, un modèle de prévision CGRU performant a été développé, capable de saisir les caractéristiques de profondeur et d'obtenir la relation temporelle de la vitesse du vent. Des expériences menées sur quatre saisons montrent que le modèle peut s'adapter à la dépendance à long terme et extraire des informations pertinentes des données brutes. [5] ont utilisé la technique CEEMDAN pour décomposer les séries temporelles en composantes plus simples

avant leur traitement par le modèle de prévision. Cette stratégie facilite l'extraction des informations pertinentes et contribue à réduire les erreurs de prédiction. [6] À travers le travail du Amirteimoury et al. 2025, un modèle proposé a été testé à l'aide de deux jeux de données de vitesse du vent différents et a obtenu une précision de prédiction élevée. De plus, 14 modèles de référence différents ont été créés et leurs résultats de prédiction ont été comparés à ceux du modèle proposé.

Parallèlement, les réseaux de neurones récurrents, notamment les architectures GRU et LSTM, ont fait l'objet d'un intérêt croissant. Dans ce cadre, [7] ont démontré la supériorité du modèle VMD-LSTM-ASSA par rapport à plusieurs modèles hybrides existants, en enregistrant une réduction importante des erreurs de prévision.

Les travaux récents montrent également une volonté d'intégrer plusieurs techniques complémentaires au sein d'un même système de prévision. À titre d'exemple, [8] ont combiné l'algorithme EEMD, le réseau GRU et les chaînes de Markov afin d'améliorer la prévision à court terme de la puissance éolienne. De manière similaire, [9] Selon Aslan et al. 2025, le modèle GRU a surpassé les autres méthodes, et l'approche hybride GRU-Weibull a produit des prévisions très cohérentes, conformes aux tendances historiques. [10] Hesty et al. 2024, ont délibéré sur le réglage fin des hypers paramètres de dix modèles d'apprentissage automatique (ML) pour obtenir le meilleur modèle de prévision, et en évaluant l'erreur quadratique moyenne (RMSE), [11] ont associé les méthodes CEEMDAN et VMD au réseau GRU dans le but d'extraire les caractéristiques spécifiques des données avant la phase de prédiction. Les résultats obtenus mettent en évidence une amélioration notable de la précision par rapport aux approches classiques.

Plusieurs études se sont également concentrées sur la réduction du bruit présent dans les séries temporelles. En effet, le bruit constitue l'un des principaux facteurs susceptibles de dégrader les performances des modèles de prévision. Pour remédier à ce problème, [12] Yao et al. 2023, ont montré que le modèle de prévision présenté permet de réduire l'erreur de prévision (RMSE) de 1,411 m/s à 0,685 m/s et d'améliorer la précision des prévisions. [13] Via la publication de Yang et al. 2022, l'approche hybride suggérée offre la possibilité de reproduire fidèlement les fluctuations des données relatives au vent [14] Huang et al. 2023, ont prouvé que le modèle CNN-GRU 3D fournit des performances idéales. Pour une prévision sur une durée de 10 minutes, les diminutions moyennes de l'erreur quadratique moyennent (RMSE) [15] ont proposé une approche intégrant des techniques avancées de débruitage associées à une version améliorée de CEEMD. Dans le même contexte, [16] ont développé le modèle CEEMD-SE-HS-KELM qui a montré des performances supérieures à celles de plusieurs modèles de référence pour la

prévision de la production éolienne. [17] Selon Ai et al. 2019, les valeurs prédites de toutes les séquences de données sont superposées afin d'obtenir les résultats finaux de prévision de la vitesse du vent. Afin d'illustrer respectivement la supériorité du traitement des caractéristiques des données et du mécanisme de prédiction.

Par ailleurs, certaines recherches ont cherché à exploiter simultanément les caractéristiques linéaires et non linéaires des séries temporelles. C'est notamment le cas de [18], qui ont proposé un modèle hybride SARIMA-EEMD-LSTM. Dans cette approche, les composantes linéaires sont extraites à l'aide du modèle SARIMA, tandis que les relations non linéaires sont modélisées par le réseau LSTM après une phase de décomposition des données. L'analyse des travaux précédents montre ainsi que les modèles hybrides constituent aujourd'hui l'une des solutions les plus prometteuses pour la prévision de la vitesse du vent. La combinaison des techniques de décomposition avec les réseaux de neurones profonds permet non seulement de réduire l'influence du bruit et de la non-stationnarité des données, mais aussi d'améliorer la capacité des modèles à capturer les comportements complexes des séries temporelles. Ces résultats justifient l'intérêt croissant porté à ce type d'approches dans les recherches récentes consacrées à l'énergie éolienne.

1.4.Principe de conversion de l'énergie cinétique du vent

L'énergie éolienne repose sur la conversion de l'énergie cinétique du vent en énergie mécanique, puis en électricité grâce à un aérogénérateur le processus de production suit quatre étapes clés :

- **Capture du vent** : Le vent exerce une force sur les pales de l'éolienne, créant un phénomène de portance aérodynamique. Les pales, fixées sur un rotor, commencent alors à tourner à une vitesse généralement comprise entre 10 et 20 tours par minute.
- **Transformation en énergie mécanique** : Le rotor est relié à un axe principal qui transmet le mouvement de rotation à l'intérieur de la nacelle.
- **Production d'électricité** : Un alternateur (ou générateur) transforme cette énergie mécanique en énergie électrique. Dans de nombreux modèles, un multiplicateur est placé entre l'axe et le générateur pour accélérer la vitesse de rotation et optimiser la production.
- **Acheminement** : Le courant produit est élevé en tension par un transformateur, puis injecté dans le réseau public d'électricité pour être distribué aux consommateurs.

1.5.Types d'éoliennes

1.5.1.L'éolienne à axe vertical

Les éoliennes à axe vertical ont été les premières structures développées pour produire de l'électricité paradoxalement en contradiction avec le traditionnel moulin à vent à axe

horizontal. Elles possèdent l'avantage d'avoir les organes de commande et le générateur au niveau du sol donc facilement accessibles et il s'agit d'une turbine à axe vertical de forme cylindrique qui peut facilement être installée sur le toit d'une maison moderne et dont les avantages sont : faible impact visuel, pratiquement pas de bruit et très grande tolérance aux vents forts. Il existe des systèmes grâce auxquels les ailes se décalent plus ou moins pour augmenter l'étendue des vitesses d'action. Si la vitesse du vent est basse, les ailes sont complètement déployées, si la vitesse est trop forte, les ailes sont complètement fermées et l'éolienne forme un cylindre. Même si quelques grands projets industriels ont été réalisés, les éoliennes à axe vertical restent toutefois marginales et peu utilisées voire actuellement abandonnées.

Les avantages théoriques d'une machine à axe vertical sont les suivantes :

- Elle vous permet de placer la génératrice, le multiplicateur, etc. à terre, et vous n'avez pas besoin de munir la machine d'une tour.
- Un mécanisme d'orientation n'est pas nécessaire pour orienter le rotor dans la direction du vent.

Les inconvénients principaux sont les suivants :

- L'efficacité globale des éoliennes à axe vertical n'est pas impressionnante.
- L'éolienne ne démarre pas automatiquement. Cependant, ceci ne constitue qu'un inconvénient mineur dans le cas d'une éolienne raccordée au réseau, étant donné qu'il est alors possible d'utiliser la génératrice comme un moteur absorbant du courant du réseau pour démarrer l'éolienne).



Fig 3. Éolienne à axe Vertical.

1.5.2. L'éolienne à axe horizontal

Les éoliennes à axe horizontal sont basées sur la technologie ancestrale des moulins à vent. Elles sont constituées de plusieurs pales profilées aéro-dynamiquement à la manière des ailes d'avion. Dans ce cas, la portance n'est pas utilisée pour maintenir un avion en vol mais pour générer un couple moteur entraînant la rotation. Le nombre de pales utilisé pour la production d'électricité varie classiquement entre 1 et 3, le rotor tripale étant le plus utilisé car il constitue

un compromis entre le coefficient de puissance, le coût et la vitesse de rotation du capteur éolien. Ce type d'éolienne a pris le dessus sur celles à axe vertical car elles représentent un coût moins important, elles sont moins exposées aux contraintes mécaniques et la position du récepteur à plusieurs dizaines de mètres du sol privilégie l'efficacité



Fig. 4. Éolienne à axe Horizontal. Nordex N80 / N90

1.5.3. Les composants principaux d'une éolienne

La figure 4 illustre de manière détaillée les divers éléments d'une éolienne.




Fig. 5. Les différents composants d'une éolienne Nordex N80 / N90

1. Pales en composite fibre de verre. Pas fixe, profil de type stall (décrochage aérodynamique). Freins aérodynamiques d'extrémité pivotants.
2. Noyau du rotor en fonte.
3. Structure de la turbine en fonte ductile ou en acier soudé galvanisé à chaud.
4. Paliers du rotor à double rangée de billes.
5. Arbre du rotor en acier de haute résistance.
6. Multiplicateur de vitesse à 3 étages (1 train épicycloïdal et 2 trains parallèles).
7. Frein à disque sur l'arbre rapide avec témoin d'usure.
8. Accouplement avec la génératrice de type flexible.
9. Génératrice (800/200 kW) asynchrone refroidie à l'eau.
10. Radiateur de refroidissement intégré au système multiplicateur - génératrice.
11. Système de mesure du vent (anémomètre et girouette) transmettant les signaux au système de contrôle de la turbine.
12. Système de contrôle surveillant et pilotant la turbine.
13. Système hydraulique pour les freins d'extrémité de pale et le système d'orientation.
14. Entraînement d'orientation de la tourelle à deux trains d'engrenages planétaires entraînés par des moteurs alimentés à fréquence variable.
15. Paliers du système d'orientation équipés d'un frein à disque.
16. Capot de la nacelle en structure acier recouverte de composite fibre de verre.
17. Tour en acier tubulaire (plusieurs hauteurs possibles).

1.6. Influence de la vitesse du vent sur la production électrique

La vitesse du vent est le facteur clé de la production éolienne : la puissance produite est proportionnelle au cube de la vitesse du vent. Une faible augmentation de vitesse entraîne une forte hausse de production, mais les éoliennes nécessitent une vitesse minimale (env. 10-15 km/h) et s'arrêtent au-delà d'une vitesse maximale (env. 90 km/h) pour sécurité. La puissance électrique (P) générée par une éolienne est modélisée par la formule

$$P = \frac{1}{2} \cdot \rho \cdot A \cdot C_p \cdot v^3 \quad (1)$$

P = puissance

ρ = la masse volumique de l'air

A = surface balayée par les pales

C_p = coefficient de puissance

v = Vitesse du vent

Donc on peut observer qu'avec l'augmentation de la vitesse du vent on augmente la puissance.

1.7.Caractéristique de la vitesse du vent

1.7.1.Nature aléatoire et non stationnaire du vent :

Le vent est un phénomène météorologique très complexe caractérisé par une nature à la fois aléatoire et non stationnaire, ce qui le rend difficile à prédire avec précision sur le long terme pour la Nature Aléatoire appelé aussi ou Stochastique c'est des turbulences de la vitesse et la direction du vent changent constamment autour d'une valeur moyenne, le phénomène appelé turbulence et même imprévisible qui ce conduit à modéliser la vitesse du vent par des processus aléatoires,

1.7.2. Variabilité temporelle (horaire, journalière et saisonnières)

Et aux mêmes temps non stationnaires c'est une évolution ou variabilité temporelle des propriétés statistiques qui changent au fil de temps par heures, jours et par saison en fonction des conditions météorologiques on peut dire que la vitesse du vent non stationnaire et variable au long du temps en fonction des conditions météorologiques, des saisons ou de la période de la journée. La variabilité temporelle du vent est caractérisée par des changements de vitesse et de direction survenant à différentes échelles, allant de quelques heures à l'année. Cette dynamique est principalement influencée par le cycle solaire, la température et les structures de pression atmosphérique et pour les changements horaires et journaliers les vents de surface sont généralement plus forts en fin de matinée et atteignent leur maximum l'après-midi. Cela est dû au réchauffement solaire qui augmente le différentiel thermique entre le sol et les couches supérieures de l'atmosphère, favorisant le mélange, et la nuit l'air se refroidit et se stabilise près du sol, ce qui réduit la vitesse du vent au niveau du sol. Et pour les variations saisonnières les vitesses du vent varient considérablement au cours de l'année, influencées par les saisons, les tempêtes et les vents forts sont plus fréquents durant certaines saisons, notamment l'hiver sur les côtes, en raison de l'activité dépressive plus intense.

1.7.3. Facteurs influençant la vitesse du vent

La vitesse du vent est le résultat d'interactions complexes entre des facteurs atmosphériques, topographiques et d'altitude elle est principalement générée par des différences de pression atmosphérique, et pour la topographie la surface terrestre joue un rôle de frein ou d'accélérateur pour le vent et même la rugosité de la surface influencer sur la vitesse du vent est plus faible au niveau du sol en raison du frottement avec des obstacles comme les arbres, les bâtiments ou le relief, qui créent des turbulences les montagnes et les collines peuvent dévier, accélérer (effet Venturi dans les vallées) ou ralentir les vents. Le vent est généralement plus fort au sommet des collines et des crêtes.

Pour les océans, les lacs et les grandes plaines offrent peu de résistance qui permettant des vitesses du vent plus élevées.

1.8. Prévision de la vitesse du vent

1.8.1. Types de prévision

- **Prévision à très court terme** : La prévision à très court terme de la vitesse du vent, souvent appelée **prévision immédiate** (*nowcasting*), couvre généralement un horizon allant de quelques minutes à 6 heures. Elle est cruciale pour la gestion de l'énergie éolienne, la sécurité aérienne et maritime. Contrairement aux prévisions météorologiques.
- **Prévision à court terme** : La prévision à court terme de la vitesse du vent (généralement de quelques minutes à 6 heures, parfois jusqu'à 72 heures) est cruciale pour la gestion des réseaux électriques, la production éolienne et la sécurité maritime. Elle s'appuie de plus en plus sur des méthodes hybrides combinant modélisation physique et intelligence artificielle et la méthode principale c'est le modèles Physiques (**NWP - Numerical Weather Prediction**) utilisent des équations de mécanique des fluides et thermodynamique (ex: modèles AROME/ARPEGE de Météo-France).
- **Prévision moyenne et à long terme** : La prévision de la vitesse du vent à moyen terme (quelques jours à quelques semaines) et long terme (saisonnier à annuel) est cruciale pour la gestion de l'énergie éolienne, l'agriculture et la modélisation climatique. Elle s'appuie sur des méthodes statistiques, des modèles numériques de prévision du temps (NWP) et de plus en plus sur l'intelligence artificielle (IA).

Pour moyen terme (**6 heures à 10-15 jours**) utilise les modèles NWP (Numerical Weather Prediction) comme ECMWF, qui sont fiables pour anticiper les systèmes météorologiques. Des techniques hybrides combinant NWP et IA (réseaux de neurones) corrigent les erreurs des modèles physiques, notamment sur des terrains complexes.

Long terme (**Saisonnier à annuel**) : Se base sur des tendances statistiques, la distribution de Weibull pour caractériser les fréquences de vent, et des réanalyses météorologiques (ex: Era Interim) pour analyser les données historiques.

1.8.2. Méthodes de Prévision

1.8.2.1. Méthodes Classiques

Les méthodes classiques de prévision de la vitesse du vent reposent sur des approches physiques, statistiques et empiriques, bien avant l'avènement massif de l'intelligence artificielle. Ces méthodes se divisent principalement en techniques d'observation directe, de modélisation mathématique et d'analyse statistique on peut citer

Méthodes d'observation et d'estimation (empirique) : Mesure directe de la vitesse en un point fixe. Les anémomètres à coupelles mesurent le vent passé, tandis que les soniques offrent une haute résolution, utile pour la turbulence.

Échelle de Beaufort : Méthode empirique, utilisée depuis 1805, qui estime la vitesse moyenne du vent (sur 10 minutes) en observant les effets du vent sur l'environnement (mer, arbres, etc.).

Ballons sondes : Utilisés pour recueillir des données sur la vitesse et la direction du vent en altitude.

1.8.2.2. Méthodes statistiques

La prévision de la vitesse du vent par des méthodes statistiques autorégressives (AR) est une approche classique et performante, particulièrement pour la prévision à court terme (quelques minutes à quelques heures). Ces méthodes modélisent la vitesse du vent comme une série temporelle où la valeur future dépend linéairement des valeurs passées, il existe trois principes de la méthode.

a) Modèle Autorégressif (AR)

La vitesse du vent (V_t) est estimée en fonction des (p) observations précédentes, plus un bruit blanc (erreur aléatoire) :

$$V_t = c + \sum_{i=1}^p Q_i V_{t-i} + \epsilon_t^* \quad (2)$$

Le vent est un phénomène non-stationnaire. Avant d'appliquer un modèle AR, il est nécessaire de rendre la série stationnaire, souvent en utilisant des différences ou en se concentrant sur des périodes courtes, et pour l'identification et Estimation les paramètres (Q_i) sont déterminés à l'aide de méthodes statistiques telles que la méthode des moindres carrés (OLS) ou les équations de Yule-Walker, généralement en analysant la fonction d'autocorrélation (ACF) et d'autocorrélation partielle (PACF)

b) Modèle Autorégressif (ARMA)

Combine la dépendance aux valeurs passées (AR) et aux erreurs de prévision passées (MA) pour mieux modéliser la structure de la série.

c) Modèle Autorégressif (ARIMA) :

Gère la non-stationnarité de la vitesse du vent en intégrant une étape de différenciation.

d) Modèle Autorégressif (SARIMA)

Prend en compte les cycles diurnes ou saisonniers du vent.

Les méthodes classiques de prévision de la vitesse du vent, telles que les modèles autorégressifs (AR), moyennes mobiles (MA) et leurs combinaisons (ARIMA, SARIMA), sont largement utilisées pour leur simplicité et leur robustesse, notamment sur le très court terme. Cependant, elles présentent des limitations significatives face à la nature complexe du vent, les principales limites sont :

- Incapacité à modéliser les relations non-linéaires ARIMA est un modèle linéaire. Or, la vitesse du vent est influencée par des facteurs atmosphériques non-linéaires (turbulence, pression, température) en plus performance réduite les modèles ARIMA peinent à capturer la dynamique complexe et la non-stationnarité des données de vent, ce qui limite leur précision par rapport aux approches d'apprentissage automatique (Machine Learning).
- Dépendance à la stationnarité Prétraitement lourd ARIMA nécessite que la série temporelle soit stationnaire (moyenne et variance constantes). La vitesse du vent étant rarement stationnaire, une différenciation (partie 'I' d'ARIMA) est nécessaire, ce qui peut perdre de l'information structurelle
- Faible performance au long terme par l'accumulation d'erreurs la composante "Moyenne Mobile" (MA) utilise les erreurs de prévision passées ces erreurs s'accumulent qui entraînant une diminution rapide de la précision lorsque l'horizon de prévision s'allonge et pour l'horizon court ils sont bons pour l'ultra-court terme (10 min à 4h) mais deviennent moins performantes pour la prévision journalière (Day Ahead)
- Incapacité à gérer les variables exogènes (seul) Approche univariée ARIMA classique n'utilise que l'historique de la vitesse du vent. Il ignore d'autres variables cruciales (direction du vent, température, pression), contrairement à des modèles comme NARX ou des réseaux de neurones
- Sensibilité aux données aberrantes (intermittence), Bruit et rafales le vent est caractérisé par une forte intermittence et des trombes soudaines, les modèles classiques lissent

souvent ces variations manquant la prévision de pics de vent cruciaux pour la sécurité des éoliennes

On peut dire que face aux approches modernes comme les réseaux de neurones (LSTM, RNN), ARIMA montre des limites notamment en termes de précision sur le moyen terme et de capacité à gérer la complexité physique du vent.

1.8.2.3. Méthodes basées sur l'intelligence artificielle

a) Réseaux de neurones artificiels (ANN)

Les réseaux de neurones artificiels (RNA ou ANN) occupent une place importante dans la prévision de la vitesse du vent grâce à leur capacité à représenter des relations complexes et fortement non linéaires entre les différentes variables météorologiques, notamment la vitesse et la direction du vent, la température, la pression atmosphérique et l'humidité. Cette aptitude leur permet de s'adapter efficacement aux comportements dynamiques et imprévisibles des phénomènes atmosphériques.

Ces modèles sont particulièrement adaptés aux prévisions à court terme, où les variations rapides des conditions météorologiques jouent un rôle déterminant. Leur principal avantage réside dans leur capacité à modéliser la non-linéarité des données, ce qui leur permet de surpasser les approches classiques linéaires telles que ARIMA, notamment dans des situations caractérisées par des fluctuations soudaines ou des changements brusques de régime de vent.

En outre, les ANN se distinguent par leur grande flexibilité, puisqu'ils peuvent être adaptés à différents sites géographiques en étant réentraînés sur des jeux de données locaux. Cette propriété est particulièrement utile dans le domaine de l'énergie éolienne, où les conditions climatiques varient fortement d'une région à une autre. Enfin, les approches modernes basées sur les réseaux de neurones profonds offrent généralement une meilleure précision de prédiction, avec une réduction notable des erreurs par rapport aux méthodes conventionnelles, ce qui renforce leur intérêt dans les systèmes de prévision intelligents.

b) Réseaux récurrents

Les réseaux de neurones récurrents (RNN), ainsi que leurs variantes avancées telles que LSTM et GRU, sont spécialement conçus pour le traitement des données séquentielles. Ils permettent de prendre en compte l'information temporelle en mémorisant les dépendances entre les observations passées et futures de la vitesse du vent, ce qui améliore considérablement la qualité des prévisions, en particulier pour les horizons courts et moyens.

c) Réseaux de neurones convolutifs (CNN)

Les CNN sont principalement utilisés pour l'extraction automatique de caractéristiques, notamment lorsqu'il s'agit de données spatiales ou structurées. Dans le contexte de la prévision

du vent, ils sont souvent intégrés dans des architectures hybrides afin de capturer des informations géographiques ou des structures locales présentes dans les champs de vent ou les données météorologiques.

d) Réseaux hybrides et modèles hybrides basés sur les techniques de décomposition

Les approches hybrides constituent aujourd'hui une direction majeure dans la prévision de la vitesse du vent, car elles permettent de combiner plusieurs méthodes complémentaires afin de mieux représenter la complexité des séries temporelles. Contrairement aux modèles classiques qui reposent sur une seule architecture, ces approches associent généralement des techniques de traitement du signal, des algorithmes d'intelligence artificielle et parfois des méthodes statistiques afin d'améliorer la précision globale.

Dans ce cadre, une première catégorie de modèles hybrides repose sur l'association des réseaux de neurones avec des méthodes de décomposition des signaux. Les techniques telles que CEEMDAN, EMD, EEMD ou encore VMD sont largement utilisées pour décomposer la série initiale de vitesse du vent en plusieurs composantes plus simples et plus stationnaires. Chaque composante est ensuite modélisée séparément à l'aide d'un algorithme d'apprentissage tel que les réseaux de neurones artificiels (ANN), les réseaux récurrents (LSTM/GRU) ou encore les modèles CNN. Les résultats finaux sont obtenus par la recombinaison des différentes prédictions, ce qui permet d'améliorer la précision globale.

Par ailleurs, certaines architectures combinent directement plusieurs modèles d'intelligence artificielle. Par exemple, les modèles CNN-LSTM exploitent la capacité des CNN à extraire des caractéristiques locales, tandis que les LSTM permettent de capturer les dépendances temporelles à long terme. De même, les architectures ANN-Fuzzy (ou ANFIS) associent les réseaux de neurones à la logique floue afin de mieux gérer l'incertitude et l'imprécision des données météorologiques.

De manière générale, l'intégration des techniques de décomposition avec les algorithmes d'apprentissage profond permet de transformer un problème complexe et non stationnaire en sous-problèmes plus simples à traiter. Cette stratégie améliore non seulement la stabilité des modèles, mais aussi leur capacité à capturer les fluctuations rapides et les comportements non linéaires des séries de vent. Ainsi, les modèles hybrides basés sur la décomposition et l'intelligence artificielle représentent aujourd'hui l'une des approches les plus performantes pour la prévision de la vitesse du vent.

1.9. Données de vent et sources ouvertes

- Importance de la qualité des données pour la précision des modèles de prévision
- Sensibilité élevée de la production éolienne aux erreurs de vitesse du vent
- Impact direct sur la gestion des réseaux électriques et l'équilibre offre/demande
- Utilisation de données fiables pour la maintenance prédictive et la sécurité des éoliennes
- Principales sources de données :
 - ERA5 (ECMWF)
 - Global Wind Atlas (GWA)
 - EMHIRES (UE)
 - NREL Wind Toolkit
 - NOAA / ISD
 - Data.gouv.fr et autres plateformes ouvertes

1.10. Conclusion

Dans ce chapitre, nous avons présenté les notions générales liées à l'énergie éolienne et à la prévision de la vitesse du vent. L'énergie éolienne représente aujourd'hui une solution importante dans la transition énergétique, grâce à son caractère renouvelable et à sa contribution à la réduction des émissions de gaz à effet de serre. Cependant, son intégration dans les réseaux électriques reste limitée par la variabilité et l'intermittence du vent, qui rendent la production difficile à prévoir avec précision. Nous avons également montré que la vitesse du vent est un phénomène complexe, aléatoire et non stationnaire, influencé par plusieurs facteurs météorologiques, topographiques et saisonniers. Cette complexité justifie le recours à des méthodes de prévision avancées. Les méthodes classiques, bien qu'utiles pour certaines applications à court terme, présentent des limites face aux comportements non linéaires et instables des séries de vent. L'état de l'art a mis en évidence l'intérêt croissant des techniques d'intelligence artificielle, notamment les réseaux de neurones récurrents tels que LSTM et GRU. Les approches hybrides combinant des méthodes de décomposition comme CEEMDAN, EMD, EEMD ou VMD avec des modèles d'apprentissage profond apparaissent particulièrement prometteuses, car elles permettent de réduire la non-stationnarité des données et d'améliorer la précision des prévisions. Ainsi, ce chapitre constitue une base théorique pour la suite du travail. Il montre que l'utilisation d'un modèle hybride basé sur la décomposition du signal et l'apprentissage profond peut représenter une solution efficace pour la prévision de la vitesse du vent.

Chapitre 2: Modélisation et méthodologie

2.1.Introduction

L'objectif de ce chapitre est de présenter la démarche permettant de concevoir un modèle de prédiction de la vitesse du vent fiable et performant, un défi complexe en raison de la nature aléatoire et non linéaire du vent.

Le processus s'articule autour de **quatre grandes étapes** :

1. **Sélection des données** : Choix d'une station météorologique basée sur la disponibilité, la continuité et la fiabilité des mesures.
2. **Nettoyage** : Élimination des valeurs manquantes, des données aberrantes et des erreurs de mesure pour maximiser la qualité du jeu de données.
3. **Normalisation** : Mise à l'échelle des variables pour faciliter l'apprentissage du réseau de neurones (type **GRU**), un modèle particulièrement sensible aux écarts de grandeur.
4. **Subdivision** : Répartition des données en trois ensembles distincts (**Apprentissage** pour l'entraînement, **Validation** pour éviter le surapprentissage, et **Test** pour l'évaluation finale).

En somme, cette chaîne de traitement rigoureuse constitue le socle indispensable à l'optimisation de la production énergétique éolienne.

2.2.Prétraitement des données

2.2.1.Sélection de la station météorologique

Dans le cadre de cette étude, les données météorologiques utilisées pour la prédiction de la vitesse du vent proviennent de la station d'Adrar, située dans le sud-ouest de l'Algérie. Le choix de cette station n'est pas fortuit, mais repose sur plusieurs considérations scientifiques et techniques liées à la nature du site et à la qualité des données disponibles la région d'Adrar se caractérise par un climat désertique aride, marqué par des températures élevées, une faible humidité et surtout un régime de vent relativement important et régulier. Ces caractéristiques font de cette zone l'une des régions les plus favorables en Algérie pour les études liées à l'énergie éolienne. Des travaux scientifiques menés sur cette région rapportent une vitesse moyenne du vent d'environ 6,2 m/s, ce qui confirme son fort potentiel éolien.

La station météorologique d'Adrar fournit des séries temporelles continues et exploitables, ce qui constitue un critère essentiel pour l'apprentissage des modèles de prédiction basés sur les réseaux de neurones. La disponibilité de données sur une période suffisamment longue permet d'analyser les variations saisonnières, journalières et aléatoires de la vitesse du vent, par ailleurs, le choix de cette station se justifie également par son importance stratégique dans les études énergétiques en Algérie, notamment pour le développement des systèmes de production d'énergie renouvelable dans les régions sahariennes. La fiabilité des mesures enregistrées par cette station permet d'obtenir une base de données robuste pour la phase de modélisation, Ainsi la station d'Adrar représente un site d'étude particulièrement pertinent pour la prédiction de la vitesse du vent, en raison de son fort potentiel éolien, de la qualité des données disponibles et de son intérêt dans les applications énergétiques.

2.2.2.Nettoyage des données

Le nettoyage des données constitue une étape fondamentale dans le traitement des séries temporelles issues de la station météorologique d'Adrar, particulièrement dans le cadre de la prédiction de la vitesse du vent. Située dans une région saharienne caractérisée par des conditions climatiques extrêmes (températures élevées, vents de sable, forte variabilité diurne), cette station peut présenter des données incomplètes ou bruitées en raison de perturbations des capteurs ou d'interruptions de transmission. Les valeurs manquantes observées dans les enregistrements de vitesse du vent sont généralement traitées à l'aide de méthodes d'imputation adaptées aux séries temporelles, telles que l'interpolation linéaire ou spline, permettant de préserver la continuité du signal. Par ailleurs, les valeurs aberrantes, souvent liées à des rafales

exceptionnelles ou à des erreurs de mesure, sont identifiées à l'aide de techniques statistiques telles que l'écart interquartile ou le score Z, puis analysées avant d'être corrigées ou supprimées selon leur pertinence physique.

Ce processus de nettoyage permet d'obtenir un jeu de données fiable et cohérent, indispensable pour améliorer la performance et la robustesse des modèles prédictifs appliqués à la vitesse du vent dans la région d'Adrar.

2.2.3. Normalisation / standardisation

Dans le cadre de la prédiction de la vitesse du vent à la station d'Adrar, le prétraitement des données est une étape indispensable. La normalisation et la standardisation sont deux techniques couramment utilisées pour rendre les variables comparables. La normalisation consiste à ramener les données dans un intervalle borné, généralement entre 0 et 1, ce qui est utile lorsque les valeurs sont bien limitées, mais elle reste sensible aux valeurs aberrantes, en compensation, la standardisation transforme les données pour avoir une moyenne nulle et un écart-type égal à un, ce qui permet de mieux gérer les variations et les fluctuations présentes dans les séries de vitesse du vent. Ainsi, le choix de la méthode dépend des caractéristiques des données et du modèle utilisé, afin d'améliorer la précision de la prédiction.

2.2.4. Découpage des données (train / validation / test) :

Le découpage des données en ensembles d'entraînement, de validation et de test constitue une étape fondamentale en apprentissage automatique, il permet d'entraîner le modèle, d'optimiser ses paramètres et d'évaluer ses performances de manière objective, tout en garantissant une bonne capacité de généralisation. Le découpage des données est une étape essentielle en apprentissage automatique, permettant d'évaluer correctement la performance d'un modèle et d'éviter le sur apprentissage, le principe c'est les données sont généralement divisées en trois ensembles entraînement (**Apprentissage**) **65%** utilisé Pour apprendre le modèle, (**Validation**) **10%** utilisé pour ajuster les paramètres et optimiser le modèle (**Test**) **25%** utilisé pour évaluer la performance finale du modèle sur des données non visuelles (fig. 6).




Fig. 6. Architecture détaillée de découpage des données

2.3.Décomposition CEEMDAN

2.3.1. Principe de CEEMDAN

Le CEEMDAN (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise) est une technique de décomposition de signaux avancée, particulièrement efficace pour prédire la vitesse du vent en raison de sa nature non stationnaire et intermittente. Il s'agit d'une version améliorée des méthodes EMD (Empirical Mode Decomposition) et EEMD (Ensemble EMD) sont des techniques adaptatives d'analyse de signaux non linéaires et non stationnaires.

L'EMD décompose un signal en fonctions de mode intrinsèque (IMF) via un processus de « tamisage ». L'EEMD améliore l'EMD en ajoutant du bruit blanc pour atténuer le problème de mélange de modes et même le Traitement des composantes (IMF) représentent les différentes échelles de fluctuation du vent et la Prédiction combinée une fois décomposées, chaque IMF peut être modélisée et prédite séparément en utilisant des techniques d'apprentissage GRU, les prédictions de chaque composante sont ensuite sommées pour reconstruire la vitesse du vent finale.

Le CEEMDAN décompose un signal $x(t)$ en un ensemble de fonctions de mode intrinsèque (IMF) et un résidu, en ajoutant un bruit blanc spécifique à chaque étape de la décomposition, plutôt qu'au début. Le signal $x(t)$ est reconstitué par la somme de ses modes

$$x(t) = \sum_{j=1}^M IMF_j(t) + R(t) \quad (3)$$

Où M est le nombre total de modes et $R(t)$ le résidu final.

Et pour l'Algorithme Mathématique est basé sur première décomposition on ajoute un bruit blanc gaussien $w^i(t)$ au signal original $x(t)$, N fois (pour $i = 1, \dots, N$) on obtient N signaux bruités :

$$x_i(t) = x(t) + \beta_0 E_1(w^i(t)) \quad (4)$$

Où $E_k(.)$ est l'opérateur qui extrait le k-ième mode (IMF) par EMD, et β_0 est un coefficient d'amplitude du bruit. Le premier mode, $IMF1(t)$, est la moyenne :

$$IMF1(t) = \frac{1}{N} \sum_{i=1}^N E_1(x_i(t)) \quad (5)$$

La deuxième étape c'est le Calcul du premier résidu $r1(t)$

$$r1(t) = x(t) - IMF1(t) \quad (6)$$

2.3.2. Application de CEEMDAN aux séries de vent

Selon la figure 7, la décomposition en composantes intrinsèques IMF (Intrinsic Mode Functions) constitue une technique avancée d'analyse des signaux non linéaires et non stationnaires, largement utilisée dans le traitement des données météorologiques et énergétiques. Basée sur la méthode Empirical Mode Décomposition ainsi que ses variantes telles que CEEMDAN, cette approche permet de décomposer un signal complexe en plusieurs composantes élémentaires appelées IMF. Chaque IMF représente une bande fréquentielle spécifique du signal original, allant des hautes fréquences associées aux fluctuations rapides jusqu'aux basses fréquences traduisant la tendance globale du phénomène étudié. Cette décomposition facilite l'analyse des caractéristiques dynamiques du signal et améliore la qualité des données utilisées pour la modélisation prédictive. Dans le domaine de la prévision de la vitesse du vent, les IMF permettent de réduire les effets du bruit et de la non-stationnarité, ce qui contribue à améliorer les performances des modèles d'intelligence artificielle tels que Gated Recurrent Unit et LSTM. Ainsi, la décomposition en IMF représente une étape essentielle pour optimiser la précision et la stabilité des systèmes de prédiction des séries temporelles météorologiques.




Fig. 7. Schéma de décomposition

2.3.3. Rôle de la décomposition dans la réduction du bruit

La décomposition en composantes intrinsèques IMF joue un rôle important dans la réduction du bruit des signaux, particulièrement dans les séries temporelles non linéaires et non stationnaires telles que les données de vitesse du vent. Grâce aux méthodes Empirical Mode Décomposition et CEEMDAN, le signal original est séparé en plusieurs composantes fréquentielles distinctes. Les premières IMF contiennent généralement les hautes fréquences et les fluctuations rapides, où se concentre une grande partie du bruit. En identifiant ces composantes bruitées, il devient possible de les filtrer, de les atténuer ou même de les éliminer avant la phase de reconstruction du signal. Cette opération permet d'obtenir un signal plus stable, plus régulier et plus représentatif du comportement réel du phénomène étudié. Dans le domaine de la prévision de la vitesse du vent, la réduction du bruit améliore considérablement la qualité des données d'entrée et augmente les performances des modèles d'apprentissage profond tels que Gated Recurrent Unit et LSTM, en réduisant les erreurs de prédiction et en améliorant la stabilité du modèle.

2.4. Réseau de neurones GRU

2.4.1. Structure interne

À travers la figure 8, le réseau de neurones Gated Recurrent Unit (GRU) est une architecture de réseau neuronal récurrent proposée pour traiter les données séquentielles et temporelles tout en réduisant le problème de disparition du gradient rencontré dans les réseaux récurrents classiques (RNN). La structure interne du GRU repose principalement sur deux mécanismes appelés porte de mise à jour (update gate) et porte de réinitialisation (reset gate). Ces portes permettent au modèle de contrôler le flux d'information et d'adapter la mémoire du réseau selon l'importance des données précédentes.

La porte de mise à jour détermine la quantité d'informations passées qui doit être conservée dans l'état caché. Elle joue un rôle similaire à la mémoire à long terme dans les modèles LSTM. Lorsque cette porte prend une valeur élevée, le réseau conserve les informations historiques importantes ; inversement, une faible valeur favorise l'intégration des nouvelles informations. Cette opération permet au modèle GRU de maintenir les dépendances temporelles sur de longues séquences.

Grâce à cette structure simplifiée comportant uniquement deux portes, le modèle GRU présente une complexité computationnelle plus faible que le modèle LSTM, tout en offrant de bonnes performances pour la modélisation et la prédiction des séries temporelles. Cette architecture est largement utilisée dans les applications de prévision de la vitesse du vent, de traitement du signal et d'analyse des données énergétiques




Fig. 8. Structure architecturale GRU

2.4.2. A..Avantages du GRU par rapport à LSTM

Le modèle Gated Recurrent Unit (GRU) présente plusieurs avantages par rapport au modèle Long Short-Term Memory (LSTM), principalement en termes de simplicité architecturale, rapidité d'exécution et coût computationnel. Contrairement au LSTM qui utilise trois portes (entrée, oubli et sortie) ainsi qu'un état mémoire supplémentaire, le GRU fonctionne uniquement avec deux portes, la porte update et la porte reset. Cette structure simplifiée réduit considérablement le nombre de paramètres à apprendre durant l'entraînement grâce à cette réduction de complexité le GRU nécessite moins de mémoire et moins de puissance de calcul ce qui accélère le processus d'apprentissage et diminue le temps d'exécution, le modèle converge souvent plus rapidement que le LSTM, particulièrement lorsque la quantité de données disponibles est limitée en plus le risque de sur apprentissage peut être réduit en raison du nombre plus faible de paramètres.

Le GRU est également mieux adapté aux applications nécessitant un traitement rapide des données temporelles, notamment dans les systèmes de prévision en temps réel tels que la prédiction de la vitesse du vent, la surveillance énergétique et le traitement des signaux. Malgré sa structure plus légère, il conserve une bonne capacité à apprendre les dépendances temporelles et offre souvent des performances comparables à celles du LSTM. On peut citer les Principaux avantages du GRU par rapport au LSTM :

- Architecture plus simple, Nombre de paramètres réduit, Temps d'entraînement plus court
Faible coût computationnel, Consommation mémoire plus faible, Convergence plus rapide, Bonne efficacité pour les séries temporelles, Adapté aux applications temps réel
Réduction possible du surapprentissage.

En conséquence, le GRU constitue une solution efficace lorsque l'objectif est d'obtenir un modèle performant avec une complexité computationnelle modérée.

2.4.3.B.. Inconvénients du modèle CEEMDAN-GRU :

Temps de calcul élevé la décomposition CEEMDAN génère plusieurs composantes IMF, puis un GRU doit être entraîné pour chaque composante, ce qui augmente fortement le coût de calcul, Complexité de mise en œuvre, le modèle comporte plusieurs étapes (décomposition, entraînement, reconstruction), ce qui le rend plus difficile à concevoir et à optimiser qu'un GRU classique, Présence de bruit résiduel et modes parasites, malgré ses améliorations par rapport à EMD et EEMD, CEEMDAN peut encore produire des IMF contenant du bruit ou des composantes parasites (« spurious modes »), Dépendance à la qualité de la décomposition, si la décomposition CEEMDAN n'est pas optimale, les prédictions du GRU seront moins précises.

2.4.3. Équations principales

La porte de réinitialisation (reset gate) contrôle l'influence des informations passées lors du calcul du nouvel état caché candidat.

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (7)$$

z_t : porte update.

x_t : entrée actuelle.

h_{t-1} : état caché précédent.

σ : fonction sigmoïde.

Elle permet au réseau d'ignorer certaines informations anciennes devenues inutiles afin de mieux s'adapter aux variations rapides de la série temporelle. Cette propriété est particulièrement utile dans les applications de prédiction des signaux non stationnaires, telles que la vitesse du vent.

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (8)$$

Le nouvel état caché candidat est ensuite calculé à partir de la combinaison entre l'entrée actuelle et l'état précédent filtré par la porte reset

$$h_t = \tanh(W_h x_t + U_h(r_t * h_{t-1}) + b_h) \quad (9)$$

Enfin, l'état caché final du GRU est obtenu en combinant l'ancien état et le nouvel état candidat selon les valeurs de la porte update :

$$h_t = ((1 - z_t) * (h_{t-1}) + z_t * (h_t)) \quad (10)$$

2.5. Modèle hybride CEEMDAN-GRU proposé

2.5.1. Architecture globale du modèle

D'après la figure 9, la méthode CEEMDAN décompose d'abord le signal initial en plusieurs éléments appelés IMF (Intrinsic Mode Functions), chaque IMF correspondant à une fréquence spécifique du signal, les premières IMF capturant les changements rapides et le bruit, les IMF au milieu illustrant les variations habituelles, tandis que les dernières IMF et le résidu reflètent la

tendance lente du signal. Chaque IMF est ensuite utilisée comme une série temporelle indépendante pour entraîner un réseau GRU, puis il apprend les relations temporelles propres à chaque composante en utilisant les valeurs passées pour prédire les valeurs futures et pour chaque IMF les données sont normalisées et les séquences d'entrée/sortie sont créées avec un lag temporel, le réseau GRU est entraîné jusqu'à minimiser l'erreur de prédiction.




Fig. 9. Schéma explicatif du modèle CEEMDAN-GRU.

2.6.Métriques d'évaluation

2.6.1. Erreur quadratique moyenne (RMSE)

Le RMSE (*Root Mean Squared Error*), ou racine de l'erreur quadratique moyenne, est une mesure statistique permettant d'évaluer l'écart moyen entre les valeurs prédites par un modèle et les valeurs réellement observées. Il est largement utilisé dans les problèmes de régression en statistique et en apprentissage automatique afin de quantifier la précision d'un modèle de prédiction. En effet, le RMSE permet de mesurer l'amplitude des erreurs commises par le modèle, tout en accordant une importance plus grande aux erreurs importantes grâce à la mise au carré des écarts.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (11)$$

y_i = valeur réelle

$\hat{y}_i$ = valeur prédite

N = nombre total des observations.

2.6.2. Erreur quadratique moyenne normalisée (NRMSE)

Le NRMSE (*Normalized Root Mean Squared Error*), ou erreur quadratique moyenne normalisée, est une métrique utilisée pour évaluer la performance d'un modèle de prédiction tout en tenant compte de l'échelle des données. Il correspond à la RMSE normalisée par une valeur de référence, généralement l'écart entre la valeur maximale et la valeur minimale des observations réelles. Cette normalisation permet de comparer les performances du modèle sur différentes séries de données.

$$\text{NRMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (12)$$

y_i = valeur réelle

$\hat{y}_i$ = valeur prédite

N = nombre total des observations.

2.6.3. Coefficient de détermination R^2

Le coefficient R^2 appelé coefficient de détermination, est une mesure statistique utilisée pour évaluer la qualité d'un modèle de prédiction ou de régression. Il indique la capacité du modèle à expliquer la variation des données réelles.

$$R^2 = \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (13)$$

y_i = valeur réelle

$\hat{y}_i$ = valeur prédite

y = moyenne des valeurs réelles

2.7.Conclusion

Ce chapitre a présenté de manière détaillée la méthodologie adoptée pour la mise en œuvre du modèle de prévision de la vitesse du vent. Dans un premier temps, les différentes étapes de prétraitement des données ont été exposées, notamment le choix de la station météorologique d'Adrar, le nettoyage des séries temporelles, ainsi que les opérations de normalisation et de découpage des données en ensembles d'apprentissage, de validation et de test. Ces étapes sont essentielles afin de garantir la qualité des données et d'assurer la fiabilité des résultats obtenus. Ensuite, une attention particulière a été accordée à la méthode de décomposition CEEMDAN, qui permet de transformer un signal complexe et non stationnaire en plusieurs composantes plus simples appelées IMF. Cette décomposition joue un rôle important dans la réduction du bruit et l'amélioration de la qualité des données, facilitant ainsi la phase de modélisation. Par la suite, le réseau de neurones GRU a été présenté en détail, en mettant en évidence sa structure interne, ses mécanismes de fonctionnement ainsi que ses avantages par rapport aux architectures classiques telles que LSTM. Grâce à sa capacité à capturer les dépendances temporelles tout en conservant une complexité computationnelle réduite, le GRU s'avère particulièrement adapté aux problèmes de prévision des séries temporelles. Enfin, l'architecture globale du modèle hybride CEEMDAN-GRU a été décrite, montrant comment la décomposition des données est combinée à l'apprentissage profond afin d'améliorer la précision des prévisions de la vitesse du vent. Les différentes métriques d'évaluation utilisées, à savoir le RMSE, le NRMSE et le coefficient de détermination R^2 , permettent de mesurer la performance et la robustesse du modèle proposé.

En conclusion, ce chapitre constitue la base méthodologique du travail, en posant les fondations nécessaires à la phase expérimentale présentée dans le chapitre suivant.

Chapitre 3

Résultats et Discussion

3.1.Introduction

Le présent chapitre est consacré aux simulations et à l'évaluation du modèle hybride CEEMDAN-GRU appliqué à la prédiction de la vitesse du vent, l'objectif principal de cette étude est d'exploiter les capacités de décomposition adaptative de la méthode CEEMDAN afin de séparer le signal éolien en plusieurs composantes intrinsèques (IMFs), puis d'utiliser le réseau de neurones récurrent GRU pour modéliser et prédire efficacement chaque composante, cette approche hybride permet de réduire l'influence du bruit, d'améliorer la représentation des variations non linéaires et non stationnaires du signal, ainsi que d'augmenter la précision des prédictions

Les simulations réalisées portent sur plusieurs étapes essentielles, notamment le prétraitement des données, la décomposition du signal par CEEMDAN, l'entraînement des réseaux GRU sur chaque IMF, puis la reconstruction de la prédiction finale, les performances du modèle sont ensuite analysées à l'aide de différents indicateurs statistiques tels que le coefficient de détermination R^2 , l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne normalisée (NRMSE). Une comparaison entre les valeurs réelles et les valeurs prédites permet également d'évaluer la capacité du modèle à suivre les fluctuations de la vitesse du vent avec une bonne précision.

Cette phase de simulation constitue ainsi une étape fondamentale pour valider l'efficacité du modèle CEEMDAN-GRU et démontrer son intérêt dans les applications de prévision des séries temporelles éoliennes.

3.2.Analyse statistique et fréquentielle des données de vitesse du vent

Avant de procéder à la phase de modélisation et de simulation, une analyse descriptive des données de vitesse du vent est réalisée afin de mieux comprendre leurs caractéristiques statistiques. Cette étape permet d'identifier les principales tendances, la dispersion ainsi que le comportement global de la série temporelle étudiée.

Chapitre 3 : Résultats et discussion

Tableau III.1 : Statistiques descriptives des données originales de vitesse du vent

Indicateur statistique	Valeur
Minimum Value	0
Maximum Value	17.819
Mean Value	6.4722
Median Value	6.704
Standard Deviation	3.2945
Variance	10.854

La figure 10 présente une analyse fréquentielle du signal de vitesse du vent dans le domaine des fréquences normalisées, en comparant le spectre du signal original avec celui du résidu obtenu après décomposition. Le spectre du signal original montre que l'énergie est principalement concentrée dans les basses fréquences (proches de 0 à 0,05), ce qui reflète la présence de tendances globales et de composantes lentes dominantes dans la dynamique du vent. En revanche, lorsque la fréquence augmente, l'amplitude du spectre diminue progressivement jusqu'à devenir quasi nulle, indiquant que les composantes de haute fréquence sont beaucoup moins énergétiques et correspondent principalement à des fluctuations rapides ou du bruit.




Figure 10 Spectres de l'intensité du signal original et du résidu de décomposition.

Par ailleurs, le résidu obtenu après décomposition est pratiquement nul sur l'ensemble du domaine fréquentiel, ce qui traduit une décomposition complète et efficace du signal initial.

Chapitre 3 : Résultats et discussion

Cette observation confirme que l'ensemble de l'information contenue dans la série temporelle a été correctement réparti entre les différentes composantes issues de la décomposition, sans perte significative d'énergie ou d'information utile.

3.3. Les Données Originales des simulations

La figure 10 présente une analyse fréquentielle (analyse spectrale dans le domaine fréquentiel) comparant le spectre de magnitude du signal d'origine (Original signal, courbe bleue) et son résidu après décomposition (Residual after decomposition, courbe orange horizontale à 0). L'essentiel de l'énergie et des composantes majeures du signal se concentre dans les très basses fréquences normalisées (entre 0 et 0,05), où la magnitude atteint ses pics les plus élevés (jusqu'à 1,2). Cela indique la présence d'une forte composante continue (DC) ou de tendances à long terme. À mesure que la fréquence normalisée augmente (au-delà de 0,1), la magnitude s'écrase vers des valeurs proches de zéro, s'apparentant à un bruit de fond haut fréquence. Le résidu après décomposition est parfaitement plat et nul (égal à 0) sur l'ensemble du spectre fréquentiel. Cette configuration démontre l'efficacité totale de la méthode de décomposition utilisée (par exemple, VMD, EMD ou ondelettes). Le fait que le résidu soit rigoureusement nul signifie que l'intégralité de l'information, des dynamiques et des fréquences du signal d'origine a été capturée et distribuée dans les modes de décomposition principaux (IMF), ne laissant absolument aucune perte d'information sous forme de résidu.




Fig .11 Signal de la vitesse du vent avant la normalisation.

Cette image 11 représente un signal brut de la vitesse du vent avant toute normalisation. On y observe une courbe bleue très fluctuante, ce qui traduit la variabilité naturelle du vent au fil des échantillons. Les oscillations montrent que la vitesse change constamment, parfois rapidement. La vitesse varie entre 0 et environ 18 m par seconde, ce qui indique des périodes de calme et des

Chapitre 3 : Résultats et discussion

pics plus forts. Il n'a pas encore été normalisé, donc on voit les valeurs réelles telles qu'elles ont été mesurées.




Fig. 12. Signale de la vitesse du vent après la normalisation

D'après la figure 12, on constate distinctement l'application de la technique Min-Max sur l'axe des ordonnées. Il est évident que toutes les valeurs initiales de la vitesse du vent ont été normalisées pour se situer obligatoirement dans un intervalle standard de 0 (vitesse minimale enregistrée) à 1 (vitesse maximale, observée à peu près au niveau de l'échantillon 5000). Le signal se compose de 18 000 échantillons (axe des x). Il présente une très forte variabilité et intermittence, ce qui est caractéristique de la nature fluctuante et aléatoire du vent. On note des phases brèves de calme (valeurs figées à 0), spécifiquement entre les échantillons 2800-3100 et 5700-6000, qui pourraient être attribuées soit à un manque complet de vent, soit à des coupures/pertes de données pendant l'enregistrement.

3.4.Choix du meilleur décalage temporel

Le choix du paramètre de retard temporel (lag) constitue une étape importante dans la conception du modèle de prédiction, car il influence directement la capacité du réseau à capturer les dépendances temporelles présentes dans la série de vitesse du vent. Afin d'identifier la valeur la plus appropriée, plusieurs simulations ont été réalisées en testant différents horizons de lag et en évaluant leurs performances à l'aide des métriques R^2 , RMSE et NRMSE. Le tableau ci-dessous présente les résultats des simulations pour le choix du meilleur lag

	Lag 2	Lag 4	Lag 6
R^2	94,59	94,60	94,62
RMSE	0,73	0,74	0,76
Nrmse	10,64	10,76	11,00

Chapitre 3 : Résultats et discussion




Fig. .13 Comparaison de performance entre les trois Lag

La figure 13 examine les performances d'un modèle de réseau de neurones récurrent de type GRU (Gated Recurrent Unit) sur un ensemble de test, en fonction de différents décalages temporels (Lag 2, Lag 4 et Lag 6).

Trois métriques complémentaires sont évaluées pour chaque décalage

- R^2 (%) (en bleu) : Le coefficient de détermination, qui reste extrêmement élevé et stable (proche de 90 %), indiquant que le modèle explique une grande partie de la variance des données.
- RMSE (en orange) : L'erreur quadratique moyenne, qui affiche des valeurs très faibles (proches de 1).
- NRMSE (%) (en jaune) : L'erreur quadratique moyenne normalisée, également stable aux alentours de 15-16 %. L'augmentation du décalage temporel (de Lag 2 à Lag 6) n'altère pas de manière significative la précision du modèle GRU. Les performances restent très stables et robustes, prouvant la capacité du réseau à capter efficacement les dépendances temporelles à plus ou moins long terme. (Figure 12)

Chapitre 3 : Résultats et discussion




Fig. 14. Comparaison du R^2 entre les trois Lag

Figure 14 illustre une comparaison de coefficient de détermination (R^2 en %) pour différents décalages temporels (Lag 2, Lag 4 et Lag 6). Pour chaque décalage, la performance est évaluée sur trois jeux distincts :

- Train (en bleu) : Le modèle obtient sa performance maximale de manière constante, avec un R^2 d'environ 95 %.
- Validation (en orange) : Les performances se maintiennent très haut, se stabilisant autour de 91 %.
- Test (en jaune) : Le score sur les données de test, totalement inédites pour le modèle, reste également excellent, avoisinant les 89-90 %.

Tout comme pour l'analyse précédente, la variation du décalage (de Lag 2 à Lag 6) n'induit aucun changement visible sur le coefficient R^2 , quelle que soit la phase de traitement (apprentissage, validation ou test). L'écart très réduit entre les résultats d'apprentissage (Train) et de généralisation (Validation/Test) démontre l'absence de surapprentissage (overfitting). Le modèle est stable, hautement performant et parfaitement robuste face à l'augmentation de l'horizon temporel.

Chapitre 3 : Résultats et discussion




Fig. 15. Comparaison du RMSE entre les trois Lag.

Une comparaison de l'erreur quadratique moyenne (RMSE) via la figure 15, pour trois décalages temporels différents (Lag 2, Lag 4 et Lag 6), répartie selon les ensembles d'apprentissage, de validation et de test. Pour chaque décalage temporel, on observe la même hiérarchie logique de l'erreur :

- Train (en bleu) : L'erreur est la plus faible (entre 0,73 et 0,76), ce qui est normal puisque le modèle s'entraîne sur ces données.
- Validation (en orange) : L'erreur augmente légèrement pour se situer autour de 0,85 - 0,87.
- Test (en jaune) : L'erreur est la plus élevée, culminant à environ 0,95 - 0,96 sur les données totalement inconnues.

Contrairement au coefficient R^2 vu précédemment, on remarque ici une très légère tendance à la hausse de l'erreur à mesure que le décalage augmente (de Lag 2 à Lag 6). Par exemple, le RMSE d'apprentissage passe d'environ 0,735 (Lag 2) à 0,76 (Lag 6). Bien que l'erreur augmente logiquement lorsqu'on tente de prédire avec un horizon temporel plus lointain (Lag 6), cette hausse reste minime et parfaitement maîtrisée. Le modèle conserve une excellente capacité de généralisation avec des valeurs de RMSE globales qui demeurent très basses (inférieures à 1) sur l'ensemble de test.




Fig. 16. Comparaison du NRMSE entre les trois Lag

Pour les figures.16, une comparaison de l'erreur quadratique moyenne normalisée (NRMSE en %) pour trois décalages temporels différents (Lag 2, Lag 4 et Lag 6), répartie selon les ensembles d'apprentissage (Train), de validation et de test. Le NRMSE permet d'évaluer l'erreur relative par rapport à la plage des données réelles.

On retrouve une distribution de l'erreur cohérente avec les observations du RMSE :

- Train (en bleu) : L'erreur relative est minimale, évoluant entre 10,6 % et 11,0 %.
- Validation (en orange) : Elle se stabilise à un niveau intermédiaire, autour de 11,5 %.
- Test (en jaune) : Elle atteint son maximum sur le jeu de test, se situant de manière constante entre 15,5 % et 15,7 %.

La hausse du NRMSE reste extrêmement faible d'un décalage à l'autre. Par exemple, pour le jeu de test, l'erreur passe d'environ 15,55 % au Lag 2 à seulement 15,70 % au Lag 6. L'erreur normalisée sur l'ensemble de test reste confinée sous la barre des 16 %, ce qui représente une excellente précision pour un modèle de prédiction basé sur des variables intermittentes. La constance des valeurs à travers les différents horizons temporels (Lag 2 à Lag 6) confirme à nouveau la stabilité et la fiabilité de généralisation du modèle

La figure 16 montre la superposition temporelle entre les valeurs réelles (Actual, courbe bleue continue) et les valeurs prédites (Predicted, courbe orange pointillée) de la vitesse du vent, en utilisant le modèle GRU avec un décalage Lag 2 sur un échantillon de 300 points. La courbe des

prédictions (orange) suit de manière extrêmement fidèle les variations, les pics et les creux de la courbe réelle (bleue).




Fig. 17. Résultats de vitesse de vent (les réelles contre les prédictifs) avec Lag2

Les dynamiques rapides et l'intermittence du vent sont captées avec précision. On n'observe pas de phénomène de "retard systématique" (time-lag effect) visible à l'œil nu, un problème pourtant fréquent lors de la prédiction de séries temporelles fluctuantes. La prédiction reste synchronisée avec la réalité. Les seules différences mineures se situent au niveau de certains pics extrêmes (par exemple, vers l'échantillon 35 ou 150), où le modèle tend à très légèrement sous-estimer ou lisser les variations abruptes. Ce graphique est la traduction visuelle des excellentes métriques obtenues précédemment (R^2 proche de 90 % et RMSE faible). Il confirme concrètement l'efficacité pratique du modèle GRU (Lag 2) pour modéliser et anticiper en temps réel le comportement hautement instable de la vitesse du vent.

3.5. Comparaison des modèles hybrides CEEMDAN-GRU et WD-GRU

Afin d'identifier l'approche hybride la plus performante pour la prévision de la vitesse du vent, une étude comparative a été réalisée entre les modèles CEEMDAN-GRU et WD-GRU. Les deux modèles utilisent le même réseau de neurones GRU comme outil de prédiction, mais diffèrent par la technique de décomposition appliquée au signal avant la phase d'apprentissage. Dans cette simulation, le lag optimal déterminé précédemment ($Lag = 2$) a été retenu pour les deux approches afin d'assurer une comparaison équitable. Les performances obtenues sont évaluées à

Chapitre 3 : Résultats et discussion

l'aide des indicateurs statistiques R^2 , RMSE et NRMSE, permettant de mesurer respectivement la qualité de l'ajustement, l'erreur moyenne de prédiction et l'erreur normalisée.

Tableau III.X : Comparaison des performances des modèles CEEMDAN-GRU et WD-GRU pour Lag = 2.

Tableau 3.2 : Évaluation des performances du modèle par les métriques statistiques.

	Lag 2 - WD-GRU	CEEMDAN-GRU
R^2	96,5115	99,3840
RMSE	1,0001	0,2741
NRMSE	16,3098	4,4699

Dans la figure 17, une comparaison sur un ensemble de test les performances de deux approches hybrides combinant la décomposition de signal et les réseaux GRU : WD-GRU (Décomposition en Ondelettes + GRU) et CEEMDAN-GRU (Décomposition Empirique en Modes Propres Ensemble Complète Adaptative avec Bruit Blanc Additif + GRU).

- R^2 (%) (en bleu) : Le modèle CEEMDAN-GRU surpasse le modèle WD-GRU en frôlant la perfection avec un score proche de 99,5 %, contre environ 96,5 % pour l'approche par ondelettes.
- RMSE (en orange) : L'erreur absolue est visiblement réduite, s'écrasant presque totalement à l'approche de 0 avec CEEMDAN.
- NRMSE (%) (en jaune) : L'erreur relative normalisée chute drastiquement, passant d'environ 16,3 % pour WD-GRU à seulement 4,2 % pour CEEMDAN-GRU.

L'intégration de la méthode de décomposition CEEMDAN offre des performances nettement supérieures à celle des ondelettes (WD). En isolant plus finement les fluctuations et les bruits du signal initial, CEEMDAN permet au modèle GRU de réaliser des prédictions d'une précision et d'une fiabilité hautement accrues sur le jeu de test.




Fig. 18. Comparaison des performances entre WD-GRU et CEEMDAN-GRU

La figure 18 illustre le processus de décomposition adaptative d'un signal complexe de vitesse du vent (Original wind speed signal, premier sous-graphique) en sous-composantes plus simples appelées fonctions de mode intrinsèque (IMF) et composante résiduelle.

- Signal d'origine : Présente une forte non-linéarité et une instabilité importante, rendant sa prédiction directe difficile.
- IMF 1 & IMF 2 : Capturent les hautes fréquences et les fluctuations à court terme. L'IMF 1, très bruitée, contient les variations les plus rapides et abruptes du vent.
- IMF 3 : Isolate une oscillation à fréquence intermédiaire, mettant en évidence des variations cycliques plus régulières.
- Comp. 4 (Résidu/Tendance) : Représente la composante à très basse fréquence. Débarrassée des bruits et des micro-fluctuations, elle trace la tendance macroscopique et l'évolution générale de la vitesse du vent sur les 4 250 échantillons.

Cette décomposition (typiquement issue d'une méthode de type EMD ou CEEMDAN) permet de "simplifier" le signal éolien. En séparant le bruit de haute fréquence de la tendance de fond, chaque sous-signal devient plus prévisible, ce qui optimise l'apprentissage ultérieur d'un modèle d'intelligence artificielle (comme un réseau GRU).




Fig. 19: . Décomposition adaptative du signal de vitesse du vent

D'après la figure 19, la distribution comparative des erreurs absolues de prédiction (Absolute prediction error) sous forme de boxplots pour les modèles WD-GRU et CEEMDAN-GRU.

- CEEMDAN-GRU : La boîte bleue est beaucoup plus basse, aplatie et proche de 0. L'erreur absolue médiane (la ligne rouge horizontale) se situe aux alentours de 0,17, traduisant une précision globale très élevée et constante.
- WD-GRU : Présente une boîte beaucoup plus étalée avec une erreur médiane nettement plus haute (environ 0,85), prouvant une dispersion des erreurs bien plus importante.
- Pour CEEMDAN-GRU, la majorité des écarts marginaux restent contenus sous la valeur de 1,0, avec seulement quelques erreurs extrêmes isolées culminant vers 2,3.
- Pour WD-GRU, les erreurs aberrantes forment une traînée dense et continue s'élevant jusqu'à 3,5, confirmant des erreurs ponctuelles majeures de prédiction.

Ce boxplot démontre visuellement la supériorité du modèle CEEMDAN-GRU. L'approche par décomposition CEEMDAN permet non seulement de diviser l'erreur moyenne par un facteur important, mais elle resserre aussi drastiquement la variance des résidus de prédiction, offrant au modèle une stabilité et une robustesse bien plus grandes que l'approche par ondelettes (WD).




Fig. .20 Comparaison de la distribution des erreurs absolues.

3.6.Évaluation des performances de modèle proposé selon différents horizons de prévision

Dans cette partie, nous évaluons les performances des deux modèles hybrides WD-GRU et CEEMDAN-GRU pour plusieurs horizons de prévision, à savoir H+3, H+6, H+12 et H+24. Le meilleur décalage temporel, correspondant à Lag 2, est conservé afin d'assurer une comparaison équitable entre les deux approches. La figure 20 présente l'évolution du coefficient de détermination (R^2) sur le jeu de test lorsque l'horizon de prévision augmente.

- Les résultats montrent une diminution progressive et attendue de la précision lorsque l'horizon devient plus long. Les valeurs de (R^2), élevées pour les horizons courts, diminuent nettement à H+24, ce qui confirme que la prévision devient plus difficile à mesure que l'on s'éloigne dans le temps. Malgré cette baisse, le modèle CEEMDAN-GRU conserve de meilleures performances que le modèle WD-GRU pour l'ensemble des horizons étudiés.
- L'avantage du modèle CEEMDAN-GRU est particulièrement visible à l'horizon H+12, où il maintient un (R^2) d'environ 83 %, alors que le modèle WD-GRU atteint environ 72 %. À l'horizon H+24, les performances des deux modèles diminuent et tendent à se rapprocher,

Chapitre 3 : Résultats et discussion

mais CEEMDAN-GRU reste légèrement supérieur. Ces résultats montrent que l'approche CEEMDAN-GRU est plus robuste pour la prévision multi-horizon de la vitesse du vent.




Fig. 21 Évolution du coefficient de détermination (R^2) sur l'ensemble de test en fonction de l'horizon de prévision. Afin d'évaluer la robustesse des modèles hybrides face à différents horizons de prévision, une analyse comparative a été réalisée entre les approches WD-GRU et CEEMDAN-GRU pour des horizons de prédiction de 3 h, 6 h, 12 h et 24 h. Les performances ont été examinées à l'aide des indicateurs RMSE et NRMSE, qui permettent respectivement de mesurer l'erreur absolue moyenne de prédiction et l'erreur relative normalisée. Les résultats obtenus sont illustrés par la figure 22.




Fig. 22. Évolution des indicateurs RMSE et NRMSE en fonction de l'horizon de prévision pour les modèles WD-GRU et CEEMDAN-GRU.

Chapitre 3 : Résultats et discussion

L'analyse de la figure 22 montre que les erreurs de prédiction (RMSE et NRMSE) augmentent avec l'horizon de prévision pour les deux modèles, ce qui est un comportement normal dans les séries temporelles. Cependant, le modèle CEEMDAN-GRU présente systématiquement des erreurs plus faibles que le modèle WD-GRU pour tous les horizons étudiés (H+3, H+6, H+12 et H+24). Cette différence est particulièrement marquée pour les horizons les plus longs, ce qui témoigne d'une meilleure stabilité et d'une plus grande précision du modèle CEEMDAN-GRU. Ces résultats confirment l'efficacité de la décomposition CEEMDAN pour améliorer les performances prédictives du réseau GRU et réduire l'impact du bruit présent dans les données de vitesse du vent.

Afin d'évaluer la capacité du modèle proposé à reproduire l'évolution réelle de la vitesse du vent, une comparaison graphique entre les valeurs mesurées et les valeurs prédites a été réalisée sur le jeu de test. Cette représentation permet d'analyser visuellement la qualité du suivi temporel du modèle CEEMDAN-GRU proposé, en particulier sa capacité à suivre les variations rapides et les fluctuations importantes de la série.




Fig. 23. Comparaison entre les valeurs réelles et prédites de la vitesse du vent par le modèle CEEMDAN-GRU proposé.

D'après la figure 23, les valeurs prédites suivent globalement la même tendance que les valeurs réelles. Le modèle CEEMDAN-GRU proposé parvient à reproduire la majorité des variations de la vitesse du vent, y compris plusieurs pics et baisses soudaines. Quelques écarts apparaissent toutefois au niveau de certaines fluctuations rapides, ce qui est attendu en raison du caractère aléatoire et non stationnaire du vent. Ces résultats confirment la bonne capacité du modèle proposé à approximer le comportement dynamique de la vitesse du vent.

Chapitre 3 : Résultats et discussion

L'analyse conjointe du RMSE et du NRMSE confirme de manière robuste que l'intégration de la méthode CEEMDAN immunise bien mieux le réseau GRU contre l'éloignement de l'horizon de prédiction. Elle offre une progression d'erreur contrôlée et une fiabilité largement supérieure à la méthode classique par ondelettes (WD), en particulier sur les prévisions à moyen terme (H+12).




Fig. .24 Comportement dynamique local du modèle optimal CEEMDAN-GRU face aux fluctuations de la vitesse du vent sur un horizon restreint de test.

Afin d'évaluer la relation entre les valeurs réelles et les valeurs prédites par le modèle proposé, un nuage de points de régression a été tracé. Ce type de représentation permet de vérifier le degré de proximité entre les prédictions du modèle CEEMDAN-GRU et les mesures réelles de la vitesse du vent. Plus les points sont proches de la droite de référence, meilleure est la qualité de prédiction.




Fig.25. Nuage de points de régression entre les valeurs réelles et prédites par le modèle CEEMDAN-GRU proposé.

Chapitre 3 : Résultats et discussion

L'analyse de l'erreur de prédiction au cours du temps permet d'examiner la stabilité du modèle proposé sur l'ensemble des échantillons du jeu de test. Cette représentation met en évidence les écarts instantanés entre les valeurs réelles et les valeurs prédites, et permet d'identifier les périodes où le modèle présente des erreurs plus importantes.




Fig. 26. Évolution temporelle de l'erreur de prédiction du modèle CEEMDAN-GRU proposé.

La distribution des erreurs de prédiction est utilisée pour analyser la concentration des erreurs autour de zéro. Une distribution centrée près de zéro indique que le modèle ne présente pas de biais important et que la majorité des prédictions restent proches des valeurs réelles.




Fig. 27. Distribution des erreurs de prédiction du modèle CEEMDAN-GRU proposé.

3.7. Conclusion

Au terme de ce chapitre, plusieurs simulations et analyses ont été réalisées afin d'évaluer les performances du modèle hybride proposé pour la prédiction de la vitesse du vent. Dans un premier temps, l'étude statistique et fréquentielle des données a permis de mieux comprendre les caractéristiques du signal éolien et de mettre en évidence sa nature fortement non linéaire et non stationnaire. Les résultats obtenus ont montré que l'étape de prétraitement, notamment la normalisation des données et le choix du décalage temporel (Lag), joue un rôle important dans l'amélioration des performances du modèle. Les différentes expérimentations réalisées sur les valeurs de Lag ont révélé que le Lag 2 constitue le meilleur compromis entre précision et stabilité des prédictions. Par ailleurs, la comparaison entre les modèles hybrides CEEMDAN-GRU et WD-GRU a mis en évidence l'apport significatif de la méthode de décomposition CEEMDAN. Les indicateurs statistiques obtenus montrent une amélioration notable de la précision de prédiction grâce à une meilleure séparation des composantes du signal et une réduction efficace du bruit. Les analyses graphiques, notamment les comparaisons entre valeurs réelles et prédites, les nuages de régression ainsi que l'étude des erreurs, confirment la capacité du modèle proposé à reproduire fidèlement la dynamique de la vitesse du vent. L'évaluation selon différents horizons de prévision a également démontré que les performances diminuent progressivement lorsque l'horizon augmente, ce qui constitue un comportement attendu dans les problèmes de prévision des séries temporelles. Néanmoins, le modèle CEEMDAN-GRU conserve des performances supérieures et une meilleure robustesse que le modèle WD-GRU pour l'ensemble des horizons étudiés. En conclusion, les résultats obtenus valident l'efficacité du modèle hybride CEEMDAN-GRU pour la prévision de la vitesse du vent. Cette approche permet d'améliorer significativement la précision des prédictions tout en assurant une bonne capacité de généralisation, ce qui la rend particulièrement adaptée aux applications liées à la gestion et à l'optimisation des systèmes de production d'énergie éolienne.

Conclusion Générale

Conclusion Générale

La prévision de la vitesse du vent constitue un enjeu majeur pour l'exploitation optimale des systèmes de production d'énergie éolienne. Cependant, le caractère aléatoire, non linéaire et non stationnaire des séries temporelles de vent rend cette tâche particulièrement complexe et nécessite le recours à des méthodes avancées de traitement du signal et d'intelligence artificielle. Dans ce mémoire, nous avons proposé une approche hybride associant la méthode de décomposition CEEMDAN (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise) au réseau de neurones récurrent GRU (Gated Recurrent Unit) pour améliorer la précision de la prévision de la vitesse du vent. La méthodologie adoptée repose sur la décomposition préalable du signal en plusieurs composantes intrinsèques (IMFs), permettant de réduire les effets du bruit et de mieux représenter les différentes dynamiques du signal avant l'étape de modélisation.

Dans un premier temps, une étude bibliographique a permis de présenter l'importance de la prévision éolienne, les principales sources de données disponibles ainsi que les différentes approches utilisées dans la littérature, notamment les méthodes statistiques, les techniques d'apprentissage automatique et les modèles hybrides. Cette analyse a mis en évidence l'intérêt croissant des méthodes combinant décomposition du signal et réseaux de neurones profonds pour améliorer les performances de prédiction.

Ensuite, la méthodologie développée a été détaillée en présentant les différentes étapes de prétraitement des données, la décomposition CEEMDAN, l'architecture du réseau GRU ainsi que la construction du modèle hybride proposé. Une attention particulière a été accordée au choix des paramètres du modèle et à l'évaluation de ses performances à l'aide des indicateurs statistiques R^2 , RMSE et NRMSE.

Les résultats expérimentaux obtenus à partir des données de la station météorologique d'Adrar ont démontré l'efficacité de l'approche proposée. Les analyses réalisées ont montré que la décomposition CEEMDAN améliore significativement la qualité des données d'entrée en isolant les différentes composantes fréquentielles du signal. Les comparaisons effectuées entre les modèles CEEMDAN-GRU et WD-GRU ont confirmé la supériorité du modèle proposé en termes de précision, de stabilité et de capacité de généralisation. De plus, les résultats obtenus pour différents horizons de prévision ont montré que le modèle CEEMDAN-GRU conserve des performances satisfaisantes même lorsque l'horizon de prédiction augmente.

En définitive, cette étude a permis de démontrer que l'intégration de la méthode CEEMDAN avec le réseau GRU constitue une solution efficace pour la prévision de la vitesse du vent. Les

performances obtenues ouvrent des perspectives intéressantes pour l'amélioration des systèmes de gestion de l'énergie éolienne et pour l'intégration accrue des sources d'énergie renouvelable dans les réseaux électriques.

Comme perspectives futures, il serait intéressant d'étendre cette étude à d'autres sites géographiques, d'intégrer des variables météorologiques supplémentaires (température, pression, humidité et direction du vent) et d'explorer d'autres architectures d'apprentissage profond telles que les modèles Transformer ou les réseaux hybrides multi-échelles afin d'améliorer davantage la précision des prévisions à moyen et long terme.

Référence bibliographie

Références

- [1] Wei, D., & Tian, Z. (2024). A comprehensive multivariate wind speed forecasting model utilizing deep learning neural networks. *Arabian Journal for Science and Engineering*, 49(12), 16809-16828.
- [2] Rhafes, M. Y., Moussaoui, O., Raboaca, M. S., & Mihaltan, T. C. (2025). A Novel Hybrid Machine Learning Framework for Wind Speed Prediction. In *E3S Web of Conferences* (Vol. 601, p. 00067). EDP Sciences.
- [3] Pandey, G., Sharma, R., & Shikhola, T. (2026). A novel hybrid framework for wind speed prediction using decomposition and gated recurrent unit networks. *Journal of Atmospheric and Solar-Terrestrial Physics*, 106799.
- [4] Jiang, Z., Che, J., He, M., & Yuan, F. (2023). A CGRU multi-step wind speed forecasting model based on multi-label specific XGBoost feature selection and secondary decomposition. *Renewable Energy*, 203, 802-827.
- [5] Syama, S., Ramprabhakar, J., Anand, R., Meena, V. P., & Guerrero, J. M. (2024). A novel hybrid methodology for wind speed and solar irradiance forecasting based on improved whale optimized regularized extreme learning machine. *Scientific Reports*, 14(1), 31657.
- [6] Amirteimoury, F., Keynia, F., Amirteimoury, E., Memarzadeh, G., & Shabanian, H. (2025). A novel wind speed prediction model based on neural networks, wavelet transformation, mutual information, and coot optimization algorithm. *Scientific Reports*, 15(1), 10860.
- [7] Wang, L., & Liao, Y. (2023). A short-term hybrid wind speed prediction model based on decomposition and improved optimization algorithm. *Frontiers in Energy Research*, 11, 1298088.
- [8] Wang, P., Su, C., Li, L., Yuan, W., & Guo, C. (2024). An ensemble model for short-term wind power
- [9] Aslan, A., Tasci, M., & Kosunalp, S. (2025). Comprehensive Assessment of Wind Energy Potential with a Hybrid GRU–Weibull Prediction Model. *Electronics*, 14(20), 4000.
- [10] Hesty, N. W., Supriatna, N. K., Kuncoro, A. H., Rahardja, M. B., & Utama, P. A. (2024). Promoting wind energy by robust wind speed forecasting using machine learning algorithms optimization.

- [11] Fang, N., Liu, Z., & Fan, S. (2025). Short-Term Wind Power Prediction Method Based on CEEMDAN-VMD-GRU Hybrid Model. *Energies*, 18(6), 1465.
- [12] Yao, H., Tan, Y., Hou, J., Liu, Y., Zhao, X., & Wang, X. (2023). Short-term wind speed forecasting based on the EEMD-GS-GRU model. *Atmosphere*, 14(4), 697.
- [13] Yang, R., Liu, H., Nikitas, N., Duan, Z., Li, Y., & Li, Y. (2022). Short-term wind speed forecasting using deep reinforcement learning with improved multiple error correction approach. *Energy*, 239, 122128.
- [14] Huang, X., Zhang, Y., Liu, J., Zhang, X., & Liu, S. (2023). A short-term wind power-forecasting model based on 3d convolutional neural network-gated recurrent unit. *Sustainability*, 15(19), 14171.
- [15] Gao, J., Xing, H., Wang, Y., Liu, G., Cheng, B., & Zhang, D. (2025). Ultra-short-term wind power prediction based on hybrid denoising with improved CEEMD decomposition. *Renewable Energy*, 251, 123352.
- [16] Wang, K., Niu, D., Sun, L., Zhen, H., Liu, J., De, G., & Xu, X. (2019). Wind power short-term forecasting hybrid model based on CEEMD-SE method. *Processes*, 7(11), 843.
- [17] Ai, X., Li, S., & Xu, H. (2023). Wind speed prediction model using ensemble empirical mode decomposition, least squares support vector machine and long short-term memory. *Frontiers in Energy Research*, 10, 1043867.
- [18] Yan, Y., Wang, X., Ren, F., Shao, Z., & Tian, C. (2022). Wind speed prediction using a hybrid model of EEMD and LSTM considering seasonal features. *Energy Reports*, 8, 8965-8980.



غرداية في : 2026/07/12

شعبة: هندسة ميكانيكية
تخصص: طاقات متجددة في الميكانيك

شهادة ترخيص بالتصحيح والاياداع:

انا الاستاذ(ة) : بكار بلقاسم
بصفتي المشرف المسؤول عن تصحيح مذكرة تخرج ماستر المعنونة بـ:

Prédiction de la vitesse du vent à l'aide d'un Modèle hybride CEEMDAN-GRU


من انجاز الطالب (الطالبة):

قصبة الحاج عيسى

التي نوقشت بتاريخ : 2026/06/13

اشهد ان الطالب قد قام بالتعديلات والتصحيحات المطلوبة من طرف لجنة المناقشة وقد تم التحقق من ذلك من طرفنا
وقد استوفت جميع الشروط المطلوبة.

مصادقة رئيس القسم



امضاء المسؤول عن التصحيح



غرداية في : 2026/05/31

إذن بالطباعة (مذكرة ماستر)

بعد الاطلاع على محتوى المذكرة المنجزة من طرف الطلبة التالية أسماؤهم:

1. الطالب (ة): قصة الحاج عيسى

تخصص : طاقات متجددة في الميكانيك

نمنح نحن الأستاذ (ة) المشرف (ة): خالد فركوس الإذن لإيداع مذكرة ماستر الموسومة بعنوان

Prédiction de la vitesse de vent à l'aide d'un Modèle hybride CEEMD-GRU

إمضاء المشرف